

Universidade Federal de Minas Gerais

Escola de Engenharia

Programa de Pós-Graduação em Engenharia Elétrica

Laboratório de Modelagem, Análise e Controle de Sistemas Não-Lineares

Av. Antônio Carlos 6627, 31270-901 Belo Horizonte, MG Brasil

Fone: +55 31 3409-3470



---

# Projeto de Sensores Virtuais e Estudo de Algoritmos para Estimação *Online* de Parâmetros em Dados com Excitação Intermitente

---

**Petrus Emmanuel Oliveira Gomes Brant Abreu**

Dissertação de Mestrado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do Título de Mestre em Engenharia Elétrica.

**Orientadores:** Prof. Alexandre Rodrigues Mesquita, Dr.  
Prof. Bruno Otávio Soares Teixeira, Dr.

Belo Horizonte - MG  
Outubro de 2016

A162p

Abreu, Petrus Emmanuel Oliveira Gomes Brant.

Projeto de sensores virtuais e estudo de algoritmos para estimação online de parâmetros em dados com excitação interminente [manuscrito] / Petrus Emmanuel Oliveira Gomes Brant Abreu. – 2016.

xxii, 86 f., enc.: il.

Orientador: Alexandre Rodrigues Mesquita.

Coorientador: Bruno Otávio Soares Teixeira.

Dissertação (mestrado) Universidade Federal de Minas Gerais, Escola de Engenharia.

Bibliografia: f. 81-85.

1. Engenharia elétrica - Teses. I. Mesquita, Alexandre Rodrigues. II. Teixeira, Bruno Otávio Soares. III. Universidade Federal de Minas Gerais. Escola de Engenharia. IV. Título.

CDU: 621.3(043)

DISSERTAÇÃO DE MESTRADO Nº 945

**PROJETO DE SENSORES VIRTUAIS E ESTUDO DE ALGORITMOS PARA  
ESTIMAÇÃO ONLINE DE PARÂMETROS EM DADOS COM EXCITAÇÃO  
INTERMITENTE**

**Petrus Emmanuel Oliveira Gomes Brant Abreu**

DATA DA DEFESA: 26/10/2016

**Petrus Emmanuel Oliveira Gomes Brant Abreu**

Dissertação de Mestrado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do grau de Mestre em Engenharia Elétrica.

Aprovada em 26 de outubro de 2016.

Por:



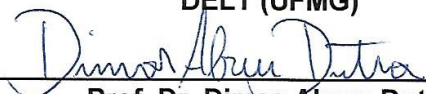
Prof. Dr. Alexandre Rodrigues Mesquita  
DELT (UFMG) - Orientador



Prof. Dr. Bruno Otávio Soares Teixeira  
DELT (UFMG) - Coorientador



Prof. Dr. Alessandro Beda  
DELT (UFMG)



Prof. Dr. Dimas Abreu Dutra  
Depto Eng Mecânica (UFMG)

---

---

# Agradecimentos

---

Agradeço primeiramente a Deus por me guiar e conceder a oportunidade de me desenvolver, de ter chegando ao final desta etapa de minha vida e início de outras que estarão por vim.

Ao meu pai, agradeço por ser mais do que um pai, ser um amigo, um homem a ser espelhado, onde o ensinamento do caráter, honestidade e humildade sempre prevaleceu. Assim como minha mãe, avôs, tios e irmão que pregam essa mesma linha de ensinamento, além das motivações e apoios dados nos momentos de dificuldades.

Aos meus orientadores, Alexandre e Bruno, que tem tido grande paciência e tranquilidade. Me ensinando e auxiliando, nesta caminhada de aprendizado. Muito obrigado.

Ao professor Luis Aguirre pela oportunidade de participar do projeto que coordena em parceria com a Petrobras, além dos conselhos e palavras de motivação.

Aos amigos do Laboratório de Modelagem, Análise e Controle de Sistemas Não-Lineares (MACSIN) com os quais tenho convivido por bons tempos, pela ajuda, conselhos e apoio. Em especial a Ana, Marcus e querida Wendy.

Aos meus amigos do Laboratório de Mechatronics Control and Robotics (MACRO) pelo companheirismo e auxílio computacional. Em especial, ao Daniel, Brenner, Juan José e Rafael.

Agradeço todo apoio financeiro proveniente da Petrobras e Fundação Christiano Ottoni. Também à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, CAPES, pela contribuição indireta ao trabalho.



---

---

# Sumário

---

<b>Agradecimentos</b>	<b>v</b>
<b>Resumo</b>	<b>xi</b>
<b>Abstract</b>	<b>xiii</b>
<b>Lista de Figuras</b>	<b>xvi</b>
<b>Lista de Tabelas</b>	<b>xvii</b>
<b>Lista de Símbolos</b>	<b>xix</b>
<b>Lista de Acrônimos</b>	<b>xxi</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Motivação . . . . .	1
1.2 Justificativa . . . . .	4
1.3 Contribuições . . . . .	6
1.4 Formulação do Problema . . . . .	6
1.4.1 Estimação da Pressão de Fundo de Poço . . . . .	6
1.4.2 Estimação da Vazão de Óleo . . . . .	7
1.5 Lista de Publicações . . . . .	8
1.6 Estrutura da Dissertação . . . . .	9
<b>2 Histórico do Problema e Literatura</b>	<b>11</b>
2.1 Descrição do Processo de Extração de Petróleo <i>offshore</i> . . . . .	11

2.1.1	Arranjo Submarino . . . . .	13
2.1.2	Instrumentação . . . . .	14
2.2	Sensores Virtuais . . . . .	17
2.3	Trabalhos Relacionados . . . . .	19
<b>3</b>	<b>Identificação de Sistemas e Filtragem: uma Visão Geral</b>	<b>23</b>
3.1	Introdução . . . . .	23
3.2	Modelagem . . . . .	24
3.2.1	Identificação de Sistemas . . . . .	26
3.2.1.1	Testes dinâmicos . . . . .	27
3.2.1.2	Seleção da estrutura de modelos . . . . .	28
3.2.1.3	Estimação de parâmetros . . . . .	28
3.2.1.4	Validação de modelos . . . . .	29
3.2.1.5	Persistência de excitação em conjunto de dados . . . . .	30
3.2.2	Modelos de Processo e Observação . . . . .	31
3.3	Filtragem . . . . .	32
3.3.1	Filtro de Kalman . . . . .	33
3.3.2	Estimação de Parâmetros Variantes no Tempo . . . . .	36
3.3.2.1	Estimação dual de estados e parâmetros . . . . .	38
3.3.2.1.1	Algoritmos recursivos com ponderação variável . . . . .	40
3.3.2.1.2	Análise para detecção de transientes em dados . . . . .	42
<b>4</b>	<b>Estimação Adaptativa em Dados com Excitação Intermitente</b>	<b>43</b>
4.1	Introdução . . . . .	43
4.2	Metodologia . . . . .	44
4.2.1	Estimadores Recursivos de Parâmetros . . . . .	44
4.2.1.1	Algoritmo fator de esquecimento variável . . . . .	44
4.2.1.2	Algoritmo fator de esquecimento variável 1 . . . . .	45
4.2.1.3	Algoritmo fator de esquecimento variável 2 . . . . .	46
4.2.1.4	Algoritmo tamanho do passo de correção . . . . .	47
4.2.2	Métodos para Estimação Dual de Estados e Parâmetros . . . . .	48

4.2.2.1	Abordagem com estimador recursivo de parâmetros . . .	49
4.2.2.2	Abordagem com estimador em batelada com detecção de transientes . . . . .	50
4.2.2.2.1	Técnica de detecção de transientes . . . . .	51
4.3	Resultados . . . . .	53
4.3.1	Análise dos Estimadores Recursivos de Parâmetros . . . . .	53
4.3.1.1	Resultados simulados . . . . .	53
4.3.1.1.1	Estudo do cenário 1 . . . . .	55
4.3.1.1.2	Estudo do cenário 2 . . . . .	58
4.3.1.1.3	Avaliação das estimativas resultantes . . . . .	60
4.3.1.2	Resultados experimentais poço R . . . . .	60
4.3.1.2.1	Estudo das estimativas . . . . .	61
4.3.1.2.2	Avaliação das estimativas resultantes . . . . .	62
4.3.2	Análise das Abordagens propostas para Estimação Dual . . . . .	62
4.3.2.1	Resultados experimentais poço R . . . . .	63
4.3.2.2	Estudo da abordagem recursiva e em batelada . . . . .	63
4.3.2.3	Avaliação das estimativas resultantes . . . . .	65
4.4	Conclusões do Capítulo . . . . .	66
<b>5</b>	<b>Sensor Virtual para Vazão de Óleo</b>	<b>67</b>
5.1	Introdução . . . . .	67
5.2	Metodologia para Análise dos Dados . . . . .	67
5.2.1	Análise do Comportamento Dinâmico . . . . .	68
5.2.2	Análise do Comportamento Estático . . . . .	69
5.3	Resultados . . . . .	71
5.3.1	Poço M . . . . .	71
5.3.2	Poço P . . . . .	73
5.4	Conclusões do Capítulo . . . . .	75
<b>6</b>	<b>Conclusões</b>	<b>77</b>
6.1	Considerações Finais . . . . .	77

6.2 Trabalhos Futuros . . . . .	79
<b>Bibliografia</b>	<b>85</b>

---

# Resumo

---

Este trabalho visa ao estudo de estimadores de parâmetros a partir de dados com excitação intermitente. O cenário de sistemas com excitação intermitente é motivado por contextos em que a estimação se baseia em dados históricos ou em que a estimação ocorre durante operação normal do processo. No último caso, tem-se como objetivo a implementação de sensores virtuais que sejam robustos a mudanças dinâmicas do sistema. O processo motivador desse trabalho é a extração de petróleo *offshore*.

Primeiramente foi realizado o estudo de algoritmos recursivos com ponderação variável para estimação de parâmetros variantes no tempo para processamento em tempo de execução. Em seguida, foi tratado o problema de estimação dual de estados e parâmetros, em que se investigaram duas abordagens para a etapa de estimação de parâmetros. A primeira abordagem é recursiva e usa os algoritmos de mínimos quadrados com ponderação variável. A segunda usa algoritmos em batelada em janelas móveis de dados para atualizar os modelos quando transientes são detectados nas mesmas. Para avaliar os algoritmos e abordagens propostas são realizados testes simulados e experimentais. O sistema simulado é um massa mola amortecedor em que a constante elástica varia com o tempo e refere-se à variável de interesse. Como teste experimental realizou-se a estimação da pressão de fundo de poço para processos *offshore* a partir de dados históricos. Os resultados obtidos sugerem que o monitoramento da persistência de excitação nos dados tornam os sensores virtuais mais robustos às mudanças dinâmicas.

Além disso, foi realizado o estudo de viabilidade do projeto de sensores virtuais para a estimação da vazão de óleo produzido em poço de petróleo. Utilizaram-se ferramentas de análise de correlação nos dados históricos disponibilizados. Porém, concluiu-se que os dados coletados para essa tarefa não possuem informação dinâmica relevante sobre o sistema, tornado o desenvolvimento de um sensor virtual uma tarefa infactível.

**Palavras-chave:** Estimação de parâmetros variantes; Algoritmos recursivos com ponderação variável; Detecção de transientes; Estimação dual de estados e parâmetros; Persistência de excitação intermitente.



---

# Abstract

---

This work studies parameter estimators for dynamical data with intermittent excitation. Systems with intermittent excitation occur in contexts in which the estimation is based on historical data or on real-time data collected during normal process operation. In the latter case, the implementation of virtual sensors that are robust to variations in the system dynamics is a typical application. The main motivation for this work is the offshore oil extraction.

First, real-time recursive algorithms with time-varying weighting for the estimation of time-varying parameters are studied. Next, the problem of dual state-and-parameter estimation is addressed and two approaches for the parameter estimation stage are investigated. The first approach is recursive and uses least squares algorithms with the time-varying weighting. The second one updates model parameters in batch mode whenever transients are detected in moving data window. To evaluate the algorithms, both simulated and experimental tests are performed. The simulated system is a mass spring damper in which the spring constant varies with time. The experimental case study regards the estimation of downhole pressure for offshore oil processes using historical data. The results suggest that monitoring persistence of excitation during run time to update models make virtual sensors more robust to dynamic variations.

In addition, the feasibility study of the virtual sensor design for the estimation of produced oil flow in oil wells was carried out. We used correlation-based analysis tools in the available historical data. However, the data collected for this task does not embody relevant dynamic information about the system, making the development of a virtual sensor an infeasible task.

**Keywords:** Time-varying parameter estimation; Recursive algorithms with variable weighting factor; Transient detection; Dual state-and-parameter estimation; Intermittent excitation.



---

# Lista de Figuras

---

1.1	Profundidade de poços <i>offshore</i> explorados pela Petrobras no Brasil. . . . .	2
1.2	Diagrama representativo do processo de medição no separador trifásico de testes. . . . .	3
1.3	Esboço das curvas características (estáticas) entre variáveis do processo com a injeção de <i>gas lift</i> para análise do controle de produção. . . . .	4
2.1	Diagrama representativo do processo de extração de óleo em águas profundas utilizando a técnica de elevação artificial por <i>gas lift</i> . . . . .	12
2.2	Ilustração de um arranjo submarino para exploração <i>offshore</i> . . . . .	13
2.3	Diagrama representativo de um separador trifásico. . . . .	14
2.4	Diagrama P&ID de um poço de petróleo com <i>gas lift</i> . . . . .	16
2.5	Diagrama para o procedimento de identificação de um sensor virtual. . . . .	18
3.1	Diagrama geral para desenvolvimento e análise de sensores virtuais. . . . .	23
3.2	Ilustração das três ferramentas de estimação relacionadas ao problema de filtragem. . . . .	33
3.3	Esquema do algoritmo do Filtro de Kalman. . . . .	35
3.4	Diagrama geral para a estimação dual de estados e parâmetros. . . . .	39
3.5	Ilustração do modo de funcionamento de alguns algoritmos com ponderação variável em dados com excitação intermitente. . . . .	42
4.1	Diagrama das abordagens propostas para atualização de parâmetros no contexto dual de estados e parâmetros. . . . .	49
4.2	Diagrama simplificado da técnica de detecção de transientes. . . . .	51
4.3	Ilustração do comportamento dinâmico dos sinais para teste no sistema massa mola amortecedor. . . . .	55
4.4	Estimativas da constante elástica para o cenário de teste 1. . . . .	56
4.5	Evolução temporal do FE e do TPC para o cenário de teste 1. . . . .	57
4.6	Estimativas da constante elástica para o cenário de teste 2. . . . .	58
4.7	Evolução temporal do FE e do TPC para o cenário de teste 2. . . . .	59
4.8	Estimativas da pressão de fundo PT1 por meio de um modelo preditivo atualizado pelo uso de algoritmos recursivos. . . . .	61

4.9	Estimativas da pressão de fundo PT1 por meio de um FK com o seu modelo de processo atualizado pelo método de estimação dual. . . . .	64
5.1	Histograma da duração em horas de cada janela no momento em que os poços E, P e M estão alinhados para testes. . . . .	68
5.2	Algumas das janelas de dados com comportamento dinâmico referentes ao Poço M, quando o mesmo está alinhado para testes. . . . .	69
5.3	Diagrama do estudo de correlação cruzada entre os intervalos de alinhamento da vazão de óleo com as demais variáveis candidatas a entrada. . . . .	69
5.4	Algumas das janelas de dados com comportamento estático referentes ao Poço M, quando o mesmo está alinhado para testes. . . . .	70
5.5	Diagrama de avaliação qualitativa da correlação estática nas janelas de alinhamento, entre a vazão de óleo e as demais variáveis do processo. . . . .	70
5.6	Função de correlação cruzada para alguns intervalos e variáveis candidatas à entrada escolhidas para o poço M. . . . .	72
5.7	Correlação estática para o poço M. Estudo entre a vazão de óleo FT5.1 e a pressão a montante da SDV de produção PT3a. . . . .	73
5.8	Função de correlação cruzada para alguns intervalos e variáveis candidatas à entrada escolhidas para o Poço P. . . . .	74
5.9	Correlação estática para o poço P. Estudo entre a vazão de óleo FT5.1 e a pressão a montante da SDV de produção PT3a. . . . .	74

---

# Lista de Tabelas

---

2.1	Descrição dos sinais de interesse medidas no processo de extração <i>offshore</i>	15
4.1	Avaliação das estimativas pelo método EPAM, para o sistema massa mola amortecedor. . . . .	60
4.2	Avaliação das estimativas pelo método EPAM, considerando o uso de um modelo preditivo para estimação da pressão de fundo no Poço R estudado. . . . .	62
4.3	Avaliação pelo método EAPM das estimativas resultantes do FK para a pressão de fundo do poço R. Considerando os algoritmos de atualização usados nas abordagens propostas para o contexto de estimação dual. . .	65
5.1	Coefficiente de correlação entre a saída vazão de óleo no separador de teste (FT5.1) com algumas das demais variáveis medidas no processo. . . . .	75



---

# Lista de Símbolos

---

## Capítulo 1

$x_k$	Vetor de estados no instante $k \in \mathbb{R}^n$ (vetor coluna de ordem $n$ );
$f$	Modelo de processo $\in \mathbb{R}^n \times \mathbb{R}^{p_f} \times \mathbb{R}^{n_\theta} \times \mathbb{R}^q \rightarrow \mathbb{R}^n$ ;
$u_{k-1}^f$	Vetor do sinal de entrada do modelo de processo no instante $k-1 \in \mathbb{R}^{p_f}$ ;
$\theta_k$	Vetor de parâmetros $\in \mathbb{R}^{n_\theta}$ ;
$w_k$	Vetor de ruído de processo $\in \mathbb{R}^q$ ;
$y_k$	Vetor do sinal de saída medido $\in \mathbb{R}^m$ ;
$h$	Modelo de observação $\in \mathbb{R}^n \times \mathbb{R}^{p_h} \times \mathbb{R}^r \rightarrow \mathbb{R}^m$ ;
$u_k^h$	Vetor do sinal de entrada do modelo de observação no instante $k \in \mathbb{R}^{p_h}$ ;
$v_k$	Vetor de ruído de medição $\in \mathbb{R}^r$ ;
$z_k$	Sinal de saída;
$\psi_{k-1}$	Vetor de regressores $\in \mathbb{R}^{n_\theta}$ ;
$e_k$	Erro de modelagem (resíduos);
$\bullet$	Valor de $\bullet$ estimado;
$\mathbb{R}$	Números reais;
$(\bullet)^T$	Transposição de vetores ou matrizes;
$\mathbb{N}$	Espaço dos números naturais;

## Capítulo 3

$\tau$	Valor de atrasos;
$r_{uy,\tau}$	Função de correlação cruzada entre dois sinais estacionário $u$ e $y$ ;
$E[\bullet]$	Esperança matemática;
$N$	Número de medições;
$\rho_{uy,\tau}$	Função de correlação cruzada normalizada;
$\sigma$	Desvio padrão;
$Z$	Vetor com medições da saída $\in \mathbb{R}^N$ ;
$\Psi$	Matriz de regressores $\in \mathbb{R}^{N \times n_\theta}$ ;
$\Xi$	Vetor do erro de modelagem (resíduos) $\in \mathbb{R}^N$ ;
$K_k$	Ganho de Kalman;
$P_k$	Matriz de covariância $\in \mathbb{R}^{n_\theta \times n_\theta}$ ;
$A_{k-1}$	Matriz dinâmica do sistema $\in \mathbb{R}^{n \times n}$ ;
$B_{k-1}$	Matriz de entrada $\in \mathbb{R}^{n \times p_f}$ ;
$C_k$	Matriz de saída $\in \mathbb{R}^{m \times n}$ ;
$D_k$	Matriz de transmissão direta $\in \mathbb{R}^{m \times p_h}$ ;
$0_{n \times m}$	Matriz de zeros;
$I_{n \times n}$	Matriz identidade;
$z^{-1}$	Atraso puro de tempo;
$\lambda_k$	Fator de esquecimento no instante $k$ ;
$g_k$	Tamanho do passo de correção no instante $k$ ;

## Capítulo 4

$\lambda_{ss}$	Fator de esquecimento em estado estacionário;
$\lambda_{tr}$	Fator de esquecimento transitório;
$d$	Erro de estimação;
$d_{th}$	Limiar superior do erro de estimação;
$\tau_{hp}$	Constante de tempo de transição entre $\lambda_{ss}$ e $\lambda_{tr}$ caso detecta-se um erro maior que $d_{th}$ ;
$\lambda_{max}$	Fator de esquecimento máximo;
$\min(\bullet)$	Operador de mínimo;
$\hat{\sigma}_{e,k}^2$ , $\hat{\sigma}_{v,k}^2$ e $\hat{\sigma}_{q,k}^2$	Desvio padrão do erro <i>a priori</i> , do ruído e do produto $q_k = \psi_k^T P_k \psi_k$ ;
$\epsilon$	Valor positivo e pequeno;
$\alpha$ e $\beta$	Fator de memória;
$\hat{e}_{f,k}$	Estimativa do erro <i>a priori</i> sem ruído;
$sgn(\bullet)$	Função sinal;
$\theta_0$	Última estimativa obtida para os parâmetros;
$P_0$	Incerteza nos parâmetros;
$r_2^{ef}$	Estimativa de posto;
$s$	Índice de correlação;

---

## Lista de Acrônimos

---

AIC	Crítério de Informação de Akaike ( <i>Akaike's Information Criterion</i> );
ANM	Árvore de Natal Molhada;
ANP	Agência Nacional do Petróleo, Gás Natural e Biocombustível;
AR	Modelo Auto Regressivo;
ARX	Modelo Auto-Regressivo com entradas eXógenas ( <i>AutoRegressive model with eXogenous inputs</i> );
CBA	Congresso Brasileiro de Automática;
DLLs	Biblioteca de Vínculo Dinâmico ( <i>Dynamic Link Library</i> );
DT	Detecção de Transientes;
EPAM	Erro Percentual Absoluto Médio;
FCC	Função de Correlação Cruzada;
FE	Fator de Esquecimento;
FEV	Fator de Esquecimento Variável;
FK	Filtro de Kalman;
FKE	Filtro de Kalman Estendido;
FKU	Filtro de Kalman <i>Unscented</i> ;
FT	Transmissor de Vazão;
FV	Abertura de Válvula;
IC	Índice de Correlação;
IIR	Resposta ao Impulso Infinita ( <i>Infinite Impulse Response</i> );
JM	Janela Móvel de Dados;
MACSIN	Grupo de Modelagem, Análise e Controle de Sistemas Não-Lineares;
MLP	Perceptron de Múltiplas Camadas ( <i>Multilayer Perceptron</i> );
MQ	Algoritmo de Mínimos Quadrados;
MQRC	Algoritmo de Mínimos Quadrados Recursivos Convencional;
MQR	Algoritmo de Mínimos Quadrados Recursivos;
MR	Matriz de Regressores;
NARX	Modelo Não-Linear Auto-Regressivo, com entradas eXógenas; ( <i>Nonlinear AutoRegressive model with eXogenous inputs</i> );
PDG	Sensor de fundo de poço permanente ( <i>Permanent Downhole Gauge</i> );
PIMS	Sistema de Gestão de Informação do Processo; ( <i>Process Information Management Systems</i> );
PRBS	Sinal binário pseudo-aleatório ( <i>Pseudo Random Binary Signal.</i> );
PT	Transmissor de pressão;
PT1	Pressão de fundo de poço;
P&D	Programa de Pesquisa e Desenvolvimento;
RNA	Redes Neurais Artificiais;
SNR	Relação Sinal Ruído ( <i>Signal Noise Ratio</i> );
TPC	Tamanho do Passo de Correção;
TT	Transmissor de Temperatura;
UFMG	Universidade Federal de Minas Gerais.



# Introdução

---

## 1.1 Motivação

O processo de extração de petróleo pode ser classificado em duas categorias de poços: *onshore* e *offshore*. Para o primeiro, tem-se que a extração de petróleo é realizada para poços localizados em terra. Os poços de exploração *offshore* correspondem àqueles no leito marinho, relacionados ao segmento de exploração em águas profundas. Neste trabalho é tratada a categoria de exploração *offshore*.

A exploração de petróleo *offshore* constitui um processo de alta complexidade, para o qual se torna necessário um desenvolvimento tecnológico contínuo de equipamentos e sistemas para a exploração e produção de petróleo em alto mar. Para situações em que se pretendem explorar novas fronteiras no mar, o desenvolvimento de equipamentos para esse propósito deve levar em consideração as dificuldades relacionadas à instalação e observação no fundo do mar, assim como, às grandes distâncias da costa marítima.

Na Figura 1.1 é mostrada a profundidade na qual a Petrobras consegue explorar petróleo no litoral brasileiro, e de certa forma, a profundidade em que alguns instrumentos são instalados. De acordo com [Morais \(2013\)](#), com o uso das tecnologias atuais pode-se alcançar profundidades para exploração de petróleo ainda maiores, chegando até cerca de 3000 metros entre as plataformas e os poços de petróleo e equipamentos no fundo do mar. Para a abertura do poço no solo marinho até o fundo do reservatório, pode-se alcançar mais de 10000 metros, resultando em uma distância total em torno de 13000 metros para a condução do petróleo até a plataforma.

Nesse ambiente de exploração de petróleo *offshore* os equipamentos se encontram sujeitos as altas pressões e salinidade, sendo esse um ambiente nocivo ao seu funcionamento e ciclo de vida. Para processos desse gênero, há diversas situações onde a troca e manutenção desses equipamentos torna-se inviável, devido a fatores relacionados a custos e segurança de operações envolvidas. No entanto, o monitoramento e controle de suas variáveis são de grande importância, pois os mesmos estão diretamente relacionados com o aumento da produtividade, a qualidade da produção, assim como, com a segurança dos equipamentos e funcionários envolvidos na operação.




Figura 1.1: Profundidade de poços *offshore* explorados pela Petrobras no Brasil. Fonte: (Max et al., 2010).

Dentre os equipamentos envolvidos nesse processo tem-se um sensor conhecido como PDG (do inglês, *permanent downhole gauge*), o qual faz o monitoramento da pressão e temperatura de fundo de poço (Eck et al., 1999). O monitoramento contínuo dessas variáveis do processo são de interesse para o controle da produção. No entanto, devido à grande profundidade e complexidade relacionada ao procedimento de parada da extração de petróleo, quando o mesmo é danificado ou para de funcionar, a sua troca e manutenção é economicamente inviável (Aggrey e Davies, 2007). Dessa maneira, quando ocorre perda de informação relevante por parte desses sensores, o sistema de controle poderá operar de forma inadequada, levando a uma queda na produção do poço de extração de petróleo.

De modo a contornar esse tipo de problema encontrado, por meio da disponibilização de medições do processo de forma contínua para os sistemas de controle da produção, é que surge a necessidade do projeto de sensores virtuais. Sensores virtuais vêm sendo aplicados nas indústrias como uma alternativa a sensores físicos. Esses sensores correspondem a modelos matemáticos para a predição de uma determinada variável de processo a partir de medições de outras variáveis (Kadlec et al., 2009).

Com isso, torna-se vantajoso o desenvolvimento de um sensor virtual que seja capaz de estimar as variáveis medidas pelo PDG quando o mesmo passar a apresentar falhas. O sensor virtual possibilita dessa maneira que o monitoramento do poço possa ser mantido mesmo que o PDG pare de funcionar, disponibilizando essas estimativas de interesse.

Outra variável que está diretamente relacionada com a eficiência produtiva da extração de petróleo é a vazão de óleo produzida (variável objetivo), que é o ponto chave a ser tratado por empresas desse ramo. Assim, o desenvolvimento de um sensor virtual para a estimação dessa variável seria desejável, já que a mesma não é aferida em tempo real de forma contínua.

As medidas de vazão disponíveis devem-se apenas a medições ocasionais e não determinísticas de cada poço em alguns instantes intervalados referentes ao alinhamento para testes. Esses testes são exigidos e aprovados pela Agência Nacional do Petróleo, Gás Natural e Biocombustível (ANP), para atribuir a medição da vazão de óleo, água e gás natural produzidos a cada poço de produção em suas plataformas. Como ilustrado no diagrama da Figura 1.2, as medidas realizadas no processo para determinar os volumes de produção são referentes a medições da vazão de óleo, água e gás para cada poço em intervalos de testes pré-determinados pela ANP.




Figura 1.2: Diagrama representativo do processo de medição no separador trifásico de testes.

Dentre as principais questões em que se focam os programas de pesquisas e desenvolvimento (P&D) realizados pelas indústrias que exploram petróleo em águas profundas, está a determinação da vazão ótima de injeção de *gas lift* em cada poço de modo que a vazão de óleo seja maximizada. A manipulação desse gás possui uma alta correlação com duas variáveis do processo, a saber, a pressão de fundo de poço e a vazão de óleo. Essa relação é ilustrada na Figura 1.3. Com base nisso, o monitoramento adequado (estimação) da vazão de óleo e/ou da pressão de fundo para cada poço de petróleo passa a ser uma tarefa valiosa. Por meio da estimação, as medições podem ser disponibilizadas continuamente para os sistemas de controle, os quais poderão manipular a vazão de *gas lift* adequadamente, de modo a otimizar a produção de óleo.

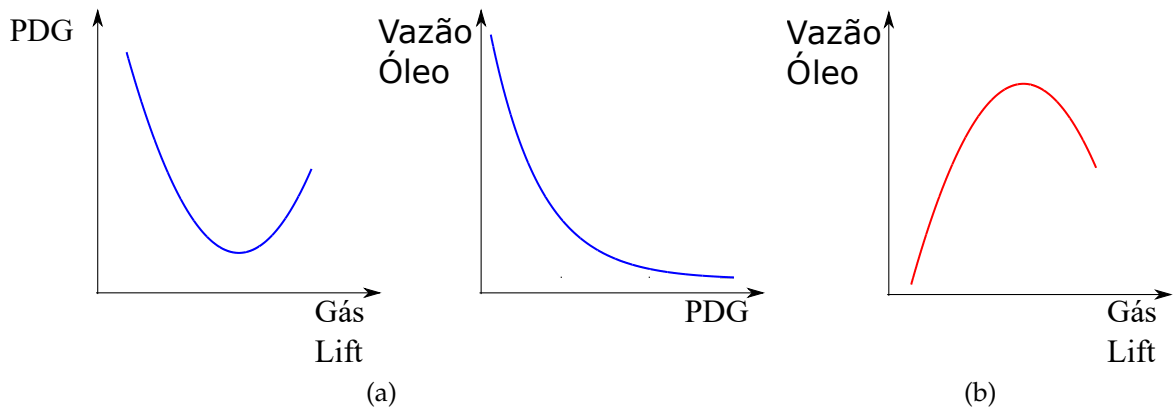


Figura 1.3: Esboço das curvas características (estáticas) entre variáveis do processo com a injeção de *gas lift* para análise do controle de produção. Na letra (a) é mostrada a relação da pressão de fundo com o *gas lift*, a qual possui relação inversa com a produção de óleo, já em (b) é mostrada a relação direta da injeção de *gas lift* com a vazão de óleo produzido.

## 1.2 Justificativa

Dentre os diversos desafios enfrentados pelas indústrias petrolíferas para exploração em poços *offshore*, têm-se as grandes profundidades para operação e as condições nocivas impostas pelo ambiente aos instrumentos de monitoramento e controle. De modo a propor soluções para esse tipo de problema encontrado em seus processos de extração, a Petrobras em conjunto com o grupo de pesquisa de Modelagem, Análise e Controle de Sistemas Não Lineares (MACSIN), na Universidade Federal de Minas Geras (UFMG), estabeleceu parceria em um projeto de pesquisa e desenvolvimento. Esse projeto tem como objetivo estudar, averiguar e desenvolver técnicas de estimação de modelos matemáticos e de processamento de sinais voltados para a extração em poços de produção de petróleo. Ao longo dessa parceria alguns trabalhos foram desenvolvidos.

Os trabalhos iniciaram com o propósito de estudar causalidade nos sinais disponibilizados pela Petrobras e propor uma ferramenta que realize essa análise automaticamente (Pankiewicz, 2011; Araújo, 2012). Tendo sido discriminados os sinais como entradas ou saídas, os demais membros do projeto passaram a trabalhar na identificação de modelos orientados a dados para a estimação da pressão de fundo de poço (Teixeira et al., 2012). Com os modelos obtidos, foram criados sensores virtuais para estimar a pressão de fundo baseados em técnicas de banco de filtros (Castro, 2013; Riccio, 2014). Técnicas baseadas em redes neurais artificiais (RNA) também foram usadas na criação de sensores para a pressão de fundo de poço (Abreu, 2013).

Outros trabalhos continuaram a ser desenvolvidos de modo a propor melhorias,

como por exemplo, o trabalho do [Proença \(2015\)](#). Seu objetivo estava em projetar sensores virtuais visando uma maior robustez às mudanças dinâmicas encontradas em cada poço, pelo uso da abordagem de estimação dual de estados e parâmetros, de modo a atualizar alguns parâmetros dos modelos de forma *online*. Para isso, foi usado o algoritmo de mínimos quadrados recursivos com fator de esquecimento constante, revisado em ([Aguirre, 2015](#), Cap. 8). Concluiu-se que a abordagem de resintonia proposta não é uma metodologia proveitosa, devido à baixa persistência de excitação nos sinais de entrada. De fato, os dados de operação correspondem em maior parte do tempo ao processo operando em condições normais, operações em regime estacionário, o que resulta em pouca informação sobre a dinâmica do sistema.

Este trabalho pretende abordar tanto a obtenção de sensores virtuais, agora focando em uma nova variável (a vazão de óleo), quanto à continuidade de propostas de melhoria para os trabalhos já desenvolvidos pelo grupo MACSIN.

Com esse propósito, este trabalho foi dividido em duas partes. Na primeira parte (I) são mostrados os estudos desenvolvidos de modo a propor melhorias aos trabalhos até então realizados pelo grupo de pesquisa. Pretende-se tornar os sensores virtuais mais robustos a mudanças gradativas na dinâmica do poço. A proposta consiste em considerar que os modelos que constituem o sensor virtual tem seus parâmetros atualizados ao longo do tempo. O diferencial da nova abordagem está no monitoramento da persistência de excitação do sinal de entrada e ajuste do modelo dinâmico apenas quando o nível de informação contido no sinal de entrada for julgado adequado. Com isso, a proposta de métodos para contornar a piora das estimativas resultantes por parte dos sensores virtuais, para o caso em que tem-se baixa persistência de excitação presente nos dados é desenvolvida.

Para alcançar esse objetivo, são realizados estudos sobre algoritmos recursivos com ponderação variável e de técnicas para detecção de transientes em janelas móveis de dados para estimação. Esses métodos são então usados para propor abordagens para se atualizar parâmetros de modelos. Com esse propósito, faz-se a estimação *online* de parâmetros de modelos por meio da técnica de estimação dual de estados e parâmetros. Como base, usam-se sensores virtuais pré-definidos em trabalhos anteriormente realizados pelo grupo do projeto, em específico os obtidos por [Proença \(2015\)](#). Os modelos que constituem esses sensores são de estrutura mais simples, modelos lineares, porém, resultados coerentes e de certa forma satisfatórios para estimação da pressão de fundo foram alcançados pelo uso desses modelos. As técnicas estudadas são de interesse geral, não sendo apenas aplicadas para a área de estimação de variáveis em processos de extração de petróleo.

Na segunda parte (II) deste trabalho são apresentados os estudos para o caso em que se pretende desenvolver um sensor virtual para estimar a vazão de óleo do poço. A dificuldade, conforme discutido acima, está no fato de as medições de vazão disponibilizadas para estudo corresponderem a medidas intervalares dessa variável, ver Figura 1.2. Estudos de viabilidade para o projeto de sensores virtuais são desenvolvidos.

## 1.3 Contribuições

O principal objetivo desta dissertação refere-se ao estudo de algoritmos e técnicas que atribuam robustez no funcionamento de sensores virtuais já existentes para a pressão de fundo de poço, e no desenvolvimento de um sensor virtual para predição da vazão de óleo produzido em diferentes poços.

Com base nisso, as principais contribuições são:

- (I) Análise comparativa de algoritmos recursivos para estimação de parâmetros variantes no tempo para o caso em que o sinal de entrada ou dados do processo possuem excitação intermitente. Testes são realizados em sistemas experimentais e simulados. Os resultados obtidos sugerem a vantagem de se utilizar algoritmos recursivos com ponderação variável, os quais de certa forma, priorizam os dados excitantes. Uma característica que produziu melhoria no desempenho desses algoritmos consiste no caso em que seja possível determinar de antemão a delimitação de máximo e mínimo valor de ponderação atribuída aos dados usados para estimação.
- (II) Proposta de abordagens para a atualização de parâmetros no contexto de estimação dual de estados e parâmetros. A ideia consiste em associar essa técnica à avaliação prévia da quantidade de informação dinâmica disponível nos dados usados para estimação. Testes em modelos que compõem sensores virtuais para predição da pressão de fundo de poço são realizados. Para uma das abordagens utilizam-se algoritmos recursivos para atualização de parâmetros. Na segunda, é aplicado um estudo de excitação dinâmica em janelas móveis de dados, atualizando os parâmetros em tempo de execução por meio de um algoritmo em batelada quando a janela em análise é considerada adequada para uso.
- (III) Desenvolvimento de um filtro adaptativo para estimação de parâmetros variantes em cenários em que a persistência de excitação é intermitente.
- (IV) Estudo de viabilidade nos dados disponibilizados para se projetar sensores virtuais com o objetivo de estimar a vazão de óleo produzido em poço de petróleo. Testes por meio de ferramentas de correlação nos dados históricos disponibilizados foram realizados. No entanto, pelas análises realizadas, concluiu-se que tais dados não possuem características dinâmicas favoráveis para tal tarefa.

## 1.4 Formulação do Problema

### 1.4.1 Estimação da Pressão de Fundo de Poço

Para o caso em que se deseja estimar a pressão de fundo de poço, têm-se sensores virtuais já desenvolvidos por outros membros do grupo de pesquisa MACSIN. Assim,

pretende-se propor metodologias que abordem a etapa de estimação de parâmetros quando tem-se dados com excitação intermitente. Essas metodologias tem por finalidade uso em sensores virtuais para a pressão de fundo de poço, buscando melhorar sua capacidade de predição.

Considere o sistema dinâmico representado no espaço de estados a tempo discreto

$$x_k = f(x_{k-1}, u_{k-1}^f, \theta_{k-1}, w_{k-1}), \quad (1.1)$$

$$y_k = h(x_k, u_k^h, v_k), \quad (1.2)$$

em que  $f : \mathbb{R}^n \times \mathbb{R}^{p_f} \times \mathbb{R}^{n_\theta} \times \mathbb{R}^q \rightarrow \mathbb{R}^n$  é o modelo de processo e  $h : \mathbb{R}^n \times \mathbb{R}^{p_h} \times \mathbb{R}^r \rightarrow \mathbb{R}^m$  é o modelo de observação,  $x_k \in \mathbb{R}^n$  é o vetor de estados,  $y_k \in \mathbb{R}^m$  é a saída medida,  $u_k = [u_{k-1}^{fT} u_k^{hT}]^T \in \mathbb{R}^{p_f+p_h}$  é a entrada assumidamente conhecida,  $w_{k-1} \in \mathbb{R}^q$  e  $v_k \in \mathbb{R}^r$  são os ruídos de processo e medição, respectivamente, e  $\theta_{k-1} \in \mathbb{R}^{n_\theta}$  é o vetor de parâmetros. Assume-se que  $\theta_k$  satisfaça ao modelo de regressão linear

$$z_k = \psi_{k-1}^T \theta_k + e_k, \quad (1.3)$$

em que  $z_k \in \mathbb{R}$  e  $\psi_{k-1} \in \mathbb{R}^{n_\theta}$  são a saída e regressores do modelo, respectivamente, tais regressores correspondem a valores presente e passados de  $x_k$  e  $u_{k-1}^f$ , e  $e_k$  é o erro de modelagem. Os modelos a serem tratados para desenvolvimento são identificados na representação ARX polinomial (do inglês, *AutoRegressive with eXogenous inputs*), a qual pode ser escrita no formato (1.3).

Pelo uso dos modelos de processo e observação, projetam-se estimadores baseados no filtro de Kalman para a predição dos estados  $\hat{x}_k$ , que correspondem neste trabalho a pressão de fundo de poço. Por meio desse tipo de sensor virtual, foi determinado como ponto de partida para estudos que o modelo de processo é variante no tempo, utilizam-se aqui de técnicas para estimação de estados e parâmetros. A escolha pelo modelo de processo como variante, ao invés do modelo de observação, deve-se a relatos feitos por outros membros do grupo MACSIN sobre a dificuldade de obter modelos de observação. Cumpre esclarecer que a extensão para o caso de ambos os modelos variantes no tempo é direta.

Para essa tarefa, emprega-se a abordagem de estimação dual de estados e parâmetros. A ideia está em usar das estimativas  $\hat{x}_k$  do filtro e das entradas  $u_{k-1}^f$ , para estimação dos parâmetros  $\hat{\theta}_k$  do modelo de processo por meio de alguma técnica de estimação de parâmetros que se considere apropriada. Dessa maneira, esses modelos são atualizados em tempo de execução de forma independente e desacoplada em relação a estimativa do filtro.

### 1.4.2 Estimação da Vazão de Óleo

Para a criação de um sensor virtual com o objetivo de se estimar a vazão de óleo produzido em determinado poço de petróleo, será dada ênfase em princípio às etapas

de identificação de sistemas. Dessa maneira, os dados coletados da vazão no separador de testes e as demais variáveis medidas no processo serão analisados, de modo a averiguar se a obtenção de modelos matemáticos preditivos para essa variável é uma tarefa factível por meio dos dados disponibilizados. Vale ressaltar que não se tem uma massa de dados contínua para estudo, e sim janelas de dados com diferentes quantidades de amostras. Essas referem-se às medidas de vazão no separador de testes que ocorrem de forma intervalar entre os poços de uma plataforma, conforme apresentado anteriormente na Figura 1.2.

Após análise dos dados, deve ser determinada a estrutura do modelo dinâmico do sistema, o qual será considerado dado por

$$z_k = \psi_{zu,k-1}^T \theta_k + e_k, \quad (1.4)$$

em que  $z_k \in \mathbb{R}$  é a saída do sistema no instante  $k \in \mathbb{N}$ ,  $\psi_{zu,k-1} \in \mathbb{R}^{n_\theta}$  corresponde aos regressores formados por combinações lineares ou não-lineares da saída  $z_{k-1}, \dots, z_{k-n_z}$ , e/ou entrada(s)  $u_{1,k}, \dots, u_{1,k-n_{u_1}}, u_{q,k}, \dots, u_{q,k-n_{u_q}}$ ,  $\theta_k \in \mathbb{R}^{n_\theta}$  são os parâmetros de ajuste e  $e_k$  é o erro de modelagem. Considerando que os regressores usados sejam lineares, as equações (1.4) e (1.3) correspondem à mesma forma de representação ARX, diferenciando apenas nas variáveis que compõem o vetor de regressores.

Para se realizar a identificação do sistema, assume-se que os dados dinâmicos  $\{z_k, u_{1,k}, \dots, u_{q,k}\}$ , em  $k=1, \dots, N$ , são conhecidos. Com isso, deseja-se estimar os parâmetros  $\theta_k$  para que o modelo dinâmico explique a dinâmica dominante subjacente a esse conjunto de dados.

## 1.5 Lista de Publicações

Os seguintes artigos científicos foram publicados durante o desenvolvimento deste trabalho.

1. (Abreu et al., 2016b) Petrus E. O. G. B. Abreu, Bruno O. S. Teixeira e Alexandre R. Mesquita. Estimação Recursiva de Parâmetros Variantes no Tempo para Sistemas com Sinal de Entrada com Excitação Intermitente. Em Anais do XXI Congresso Brasileiro de Automática. (CBA 2016), Vitória, ES.
2. (Abreu et al., 2016a) Petrus E. O. G. B. Abreu, Bruno O. S. Teixeira e Alexandre R. Mesquita. Abordagem para Atualização de Parâmetros no Contexto de Estimação Dual de Estados e Parâmetros. Em Anais do XXI Congresso Brasileiro de Automática. (CBA 2016), Vitória, ES.

## 1.6 Estrutura da Dissertação

Esta dissertação está organizada em seis capítulos da seguinte forma:

Neste Capítulo formulou-se o problema estudado nessa dissertação, motivando o estudo do mesmo a partir de uma breve análise da literatura.

O Capítulo 2 disserta sobre o estado da arte do problema estudado neste trabalho, especificamente o desenvolvimento de sensores virtuais. Além disso, faz-se uma breve descrição do processo para o qual os sensores foram descritos.

No Capítulo 3 faz-se uma apresentação das principais ideias relacionadas as técnicas de identificação de sistemas e filtragem estocásticas usadas neste trabalho.

Os resultados deste trabalho são divididos em duas partes. Na parte I faz-se o estudo de estimação adaptativa para dados com persistência de excitação intermitente, pretendendo tornar os sensores virtuais para estimação da pressão de fundo de poço mais robustos a mudanças dinâmicas do poço. A parte II apresenta o estudo de viabilidade para o projeto de sensores virtuais para estimação da vazão de óleo produzido por diferentes poços.

Optou-se por agrupar no Capítulo 4 tanto os resultados da parte I quanto previamente a descrição dos principais métodos usados nesta parte. Semelhantemente no Capítulo 5 estuda-se a parte II, neste capítulo também fez-se uma breve revisão da metodologia usada e principais ferramentas utilizadas.

O Capítulo 6, por fim, traz as conclusões com as considerações finais sobre o trabalho e algumas propostas para pesquisas de trabalhos futuros.



## Histórico do Problema e Literatura

---

### 2.1 Descrição do Processo de Extração de Petróleo *offshore*

Nesta seção é realizada uma breve descrição do processo de extração de petróleo *offshore*. Em relação ao processo, pretende-se abranger a parte referente ao seu arranjo submarino de modo a citar suas etapas de execução, além de especificar as variáveis de interesse envolvidas no mesmo.

Segundo [Thomas \(2001\)](#), a extração de petróleo *offshore*, também referenciada como processos de extração de petróleo em águas profundas, consiste de poços que podem ser classificados como surgentes ou não surgentes. No primeiro tipo, tem-se que a pressão no poço é alta o suficiente para elevar seus fluidos (mistura de óleo, água e gás) até a superfície de forma natural. Já para o segundo, tal reservatório tem uma pressão relativamente baixa, sendo necessário o uso de técnicas artificiais para auxiliar na elevação desse fluido. Em muitos casos, ao final da vida útil do poço ou quando o mesmo possui uma vazão abaixo da desejada para produção, as técnicas de elevação artificial também são valiosas para serem utilizadas.

Entre os métodos de elevação artificial, o mais comumente utilizado é a técnica de *gas lift*, a qual consiste da injeção de gás comprimido para elevar o fluido no fundo do poço até a superfície. Esse transporte é possível devido à injeção de gás reduzir a densidade do fluido produzido no poço, diminuindo assim a pressão entre o fundo do poço e a superfície ([Eikrem, 2006](#)). Na Figura 2.1, é apresentado um esquema simplificado desse processo da injeção de *gas lift* em um poço de produção.

Como pode ser notado na Figura 2.1, tem-se uma estação de compressores que fornece gás comprimido a um sistema de controle que é responsável por determinar a vazão de gás a ser injetada no poço para maximizar sua produção. Esse gás entra em contato com o fluido explorado por meio de válvulas que estão distribuídas ao longo da coluna de produção, auxiliando assim no transporte desse fluido até a superfície.

O cenário tratado neste trabalho refere-se à produção de petróleo em poços *offshore*, não surgentes, que utiliza da técnica de *gas lift* como método de elevação artificial dos fluidos de produção. A seguir descreve-se brevemente como o processo de produção evolui a partir do poço até a plataforma.




Figura 2.1: Diagrama representativo do processo de extração de óleo em águas profundas utilizando a técnica de elevação artificial por *gas lift*. Fonte: (Proença, 2015).

### 2.1.1 Arranjo Submarino

O arranjo submarino consiste especificamente dos dutos e equipamentos envolvidos no transporte dos fluidos vindos do fundo dos poços de produção até às plataformas, as quais podem ser fixas ou flutuantes. Na Figura 2.2 esse arranjo é apresentado de modo ilustrativo.




Figura 2.2: Ilustração de um arranjo submarino para exploração *offshore*. Em destaque têm-se: alguns tipos de plataformas (1), as tubulações de *risers* (2) e *flowline* (3), o *manifold* (4), a ANM (5) e a *coluna de produção* (6). Fonte: Adaptada de (ODI/PREnergia, 2012).

A condução do fluido explorado se inicia na coluna de produção, essa é formada por tubos metálicos e válvulas responsáveis pelo transporte desse fluido até a cabeça do poço no leito submarino. Tal coluna é mostrada como parte do processo de extração por *gas lift* apresentado na Figura 2.1 e a tubulação referente ao item (6) na Figura 2.2.

Na cabeça de poço têm-se válvulas, conexões e adaptadores que são acoplados à coluna de produção, sendo essa estrutura denominada como árvore de natal molhada (ANM). Antes de elevar tal fluido até a superfície, comumente concatenam-se as ANMs próximas, de modo que a produção de vários poços fluam por apenas uma tubulação, sendo o *manifold* submarino de produção o responsável por essa tarefa. A partir desse, o fluido passa por dutos que são fixos no leito submarino, denominados de *flowline*, e uma parte suspensa que chega à plataforma chamada de *riser* (Thomas, 2001).

Ao chegar à plataforma, o fluido extraído é submetido a um processo de separação, comumente trifásica, no qual pretende-se separar o óleo, a água e o gás presentes no mesmo, conforme mostrado de modo simplificado na Figura 2.3. Em seguida, destinam-se de forma adequada tais substâncias ao descarte ou armazenamento. Para esse último, faz-se o transporte dessa para refinarias no continente, nas quais tais substâncias passam por outros processamentos.




Figura 2.3: Diagrama representativo de um separador trifásico. Fonte: (Thomas, 2001).

### 2.1.2 Instrumentação

Para o processo de extração *offshore* aqui estudado, e apresentado na Subseção 2.1.1, têm-se que as variáveis ao longo do processo são monitoradas por sensores e manipuladas por válvulas automáticas.

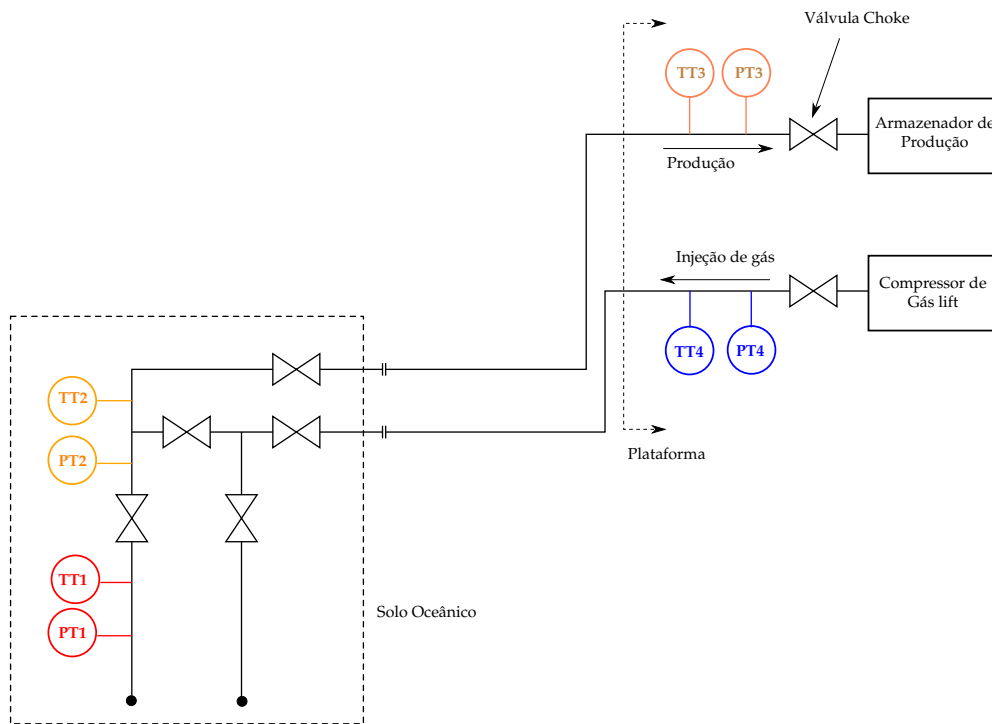
Para o desenvolvimento deste trabalho, tem-se que dados coletados de sensores referentes a poços de diferentes plataformas da Petrobras são disponibilizados para os estudos. Esses dados são coletados por meio de um Sistema de Gestão de Informação do Processo (PIMS, do inglês *Process Information Management Systems*) que coletam as informações considerando um intervalo de amostragem de 1 minuto. As principais variáveis de interesse sobre o processo são apresentadas na Tabela 2.1, por meio de seus respectivos *tags*, descrição e sua respectiva unidade de medida.

Tabela 2.1: Variáveis medidas no processo *offshore*. Fonte: Adaptada de (Teixeira et al., 2014).

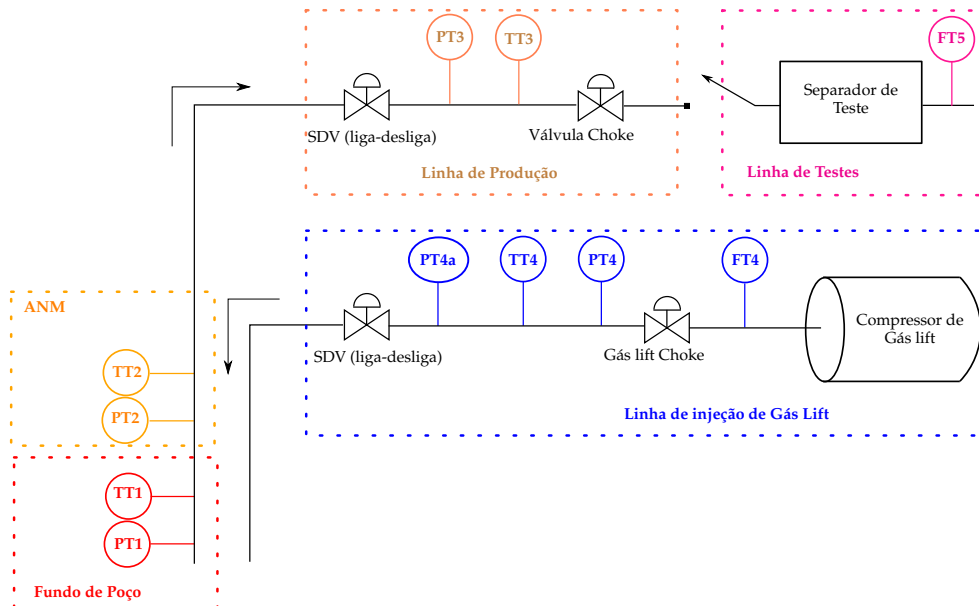
Tag	Descrição	Unidade
PT1	Pressão de fundo de poço	kgf/cm <sup>2</sup>
TT1	Temperatura de fundo de poço	°C
PT2	Pressão na árvore de natal molhada	kgf/cm <sup>2</sup>
TT2	Temperatura na árvore de natal molhada	°C
PT3a	Pressão a montante da SDV de produção	kgf/cm <sup>2</sup>
PT3	Pressão a montante do choke de produção	kgf/cm <sup>2</sup>
PT3b	Pressão a jusante do choke de produção	kgf/cm <sup>2</sup>
TT3	Temperatura a montante do choke de produção	°C
FV3	Abertura da válvula do choke de produção	%
PT4b	Pressão a jusante da SDV de gás-lift	kgf/cm <sup>2</sup>
PT4a	Pressão a montante da SDV de gás-lift	kgf/cm <sup>2</sup>
TT4	Temperatura a montante da SDV de gás-lift	°C
FT4	Vazão instantânea de gás-lift	m <sup>3</sup> /h
FV4	Abertura da válvula de gás-lift	%
PT4	Pressão a jusante do choke de gás-lift	kgf/cm <sup>2</sup>
FT5.1	Vazão de óleo no Separador de teste	m <sup>3</sup> /h
FT5.2	Vazão de água no Separador de teste	m <sup>3</sup> /h
FT5.3	Vazão de gás no Separador de teste	m <sup>3</sup> /h

Os *tags* possuem uma numeração que faz referência ao ponto em que determinado sensor ou válvula está instalado. Primeiramente, têm-se que são dispostas medidas determinadas como, TT, PT e FT referentes a transmissores de temperatura, pressão e vazão respectivamente, e os referentes à abertura de válvulas determinados como FV. As numerações especificadas como 1 e 2 fazem referência a variáveis no leito marinho, respectivamente às medidas no fundo de poço e na ANM. As *tags* referenciadas como 3, 4 e 5 correspondem a medidas na superfície, respectivamente, na linha de produção, na linha de injeção de *gas lift* e nas saídas do separador de testes; veja Figura 2.3. As medidas do separador de testes são usadas a princípio como forma de atribuir a produção para cada poço analisado.

Para uma melhor compreensão de como alguns desses instrumentos e seus respectivos sinais estão dispostos no processo, tem-se o diagrama de instrumentação mostrado na Figura 2.4. Nele, é apresentada uma visão simplificada em que se diferenciam as variáveis encontradas no oceano e na plataforma, Figura 2.4(a), e uma descrição mais detalhada de algumas das variáveis da superfície, Figura 2.4(b). Dois tipos de válvulas são encontradas, as SDV (do inglês, *shutdown valve*), referentes a válvulas de segurança para interromper o fluxo e as válvulas *choke* de estrangulamento, usadas para regulação das vazões nas linhas de produção e de injeção de *gas lift*. Na Figura 2.4, também é apresentado o fluxo do processo, o qual inicialmente parte da injeção de gás por meio da tubulação de *gas lift* na direção da plataforma, passando pelo fundo de poço, em seguida pela ANM e então chegando à linha de produção por onde o fluido é transportado até a plataforma.



(a)



(b)

Figura 2.4: Diagrama P&ID de um poço de petróleo com *gas lift*, em que TT, PT e FT são os transmissores de temperatura, pressão e vazão. Em (a) é apresentada uma visão geral do processo, enquanto em (b) é mostrada uma visão mais detalhada dos instrumentos da plataforma. Os números 1 (fundo de poço) e 2 (árvore de natal molhada) representam variáveis no leito marinho, enquanto 3 (produção), 4 (*gas lift*) e 5 (separador de teste) tratam variáveis da plataforma. A direção do fluxo é 4-1-2-3. As variáveis do fundo do poço são medidas próximas à saída do reservatório. Baseado em: (Teixeira et al., 2014).

## 2.2 Sensores Virtuais

O desenvolvimento de sensores virtuais tem surgido como alternativa ao uso de sensores físicos e têm ganhado espaço em aplicações industriais diversas, como nos exemplos citados a seguir. Em (Yan et al., 2004), é apresentado o uso de um sensor virtual para a estimativa do ponto de congelamento do óleo diesel em uma unidade de craqueamento de fluido catalítico. Garcia et al. (2013) realiza a estimação da orientação no espaço de um satélite artificial com base em dados reais do satélite CBERS (China-Brasil Earth Resources Satellite). Já no contexto petroquímico, Aggrey e Davies (2007) utilizam de técnicas de redes neurais artificiais para criar sensores virtuais para a estimativa da pressão de fundo de poço de petróleo.

O sensor virtual (termo do inglês, *soft-sensor*) tem sua denominação advinda da combinação das palavras software e sensor, pelo fato de ser uma ferramenta implementada em computador para funcionar como hardware (sensor). Essa ferramenta é comumente dividida em duas classes para desenvolvimento. Uma das classes é nomeada como sensores orientados a modelos, que utiliza de conhecimentos da física do processo, e outra de sensores orientados a dados, que usa de técnicas da identificação de sistemas. Os sensores virtuais orientados a dados têm ganhado popularidade em aplicações industriais, pelo fato de seu desenvolvimento utilizar de observações empíricas (dados medidos da planta) ao invés de necessitar obter o modelo físico, que muitas vezes não é uma tarefa trivial (Kadlec et al., 2009).

De acordo com Fortuna et al. (2007), os sensores virtuais apresentam características vantajosas em relação aos sensores físicos. Dentre algumas vantagens tem-se o fato de eles representarem uma alternativa de baixo custo, e poderem ser utilizados como detectores de falha para sensores físicos em funcionamento, aumentando a confiabilidade da medição. A manutenção de sensores virtuais, na maioria dos casos, se reduz ao ajuste de parâmetros. Por outro lado, sensores físicos dependem da realização de troca. Esse cenário corresponde à situação encontrada pelo sensor PDG, o qual é instalado no fundo do poço de produção.

Ao considerar o desenvolvimento de sensores virtuais orientados a dados, ferramenta tratada neste trabalho, tem-se como principal abordagem as técnicas aplicadas na área da identificação de sistemas para obtenção de modelos. A área de identificação de sistemas tem como objetivo propor métodos para a obtenção de modelos que sejam capazes de explicar a relação de causa e efeito presente em dados de entrada e saída. Uma das “vantagens” e principais características dessas técnicas está no fato de que não é necessário, em primeira instância, ter conhecimento sobre a física do sistema que se deseja identificar. Com isso, essas técnicas são referidas como identificação caixa-preta ou modelagem empírica (Aguirre, 2015).

Para sensores virtuais orientados a dados, Fortuna et al. (2007) apresenta a metodologia descrita na Figura 2.5, para o procedimento de identificação quando apenas dados históricos estão disponíveis para o projeto de um sensor virtual.

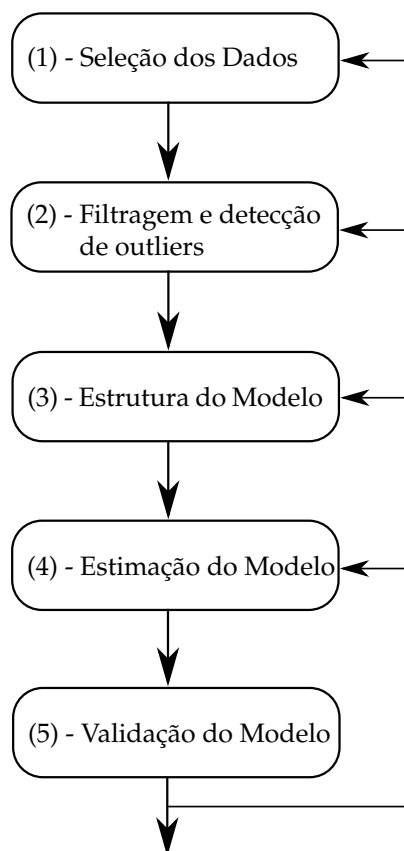


Figura 2.5: Diagrama para o procedimento de identificação de um sensor virtual. Baseado em: (Fortuna et al., 2007).

Disponer apenas de dados históricos de uma planta industrial é uma situação comumente encontrada nos casos reais para o projeto de sensores virtuais. Nem sempre testes podem ser realizados. Assim, uma análise dos dados disponibilizados sobre a operação do processo de interesse deve ser realizada de modo a determinar se esses dados são ou não adequados para o projeto de sensores.

Após análise dos dados históricos para detecção de transientes, passo (1), um segundo passo pode ser realizado para tratamento desses dados, dependendo da qualidade dos mesmos. No passo (2), tem-se o uso de técnicas relacionadas a processamento e filtragem de sinais, de modo a eliminar valores espúrios e *outliers*.

No passo (3), é necessário determinar qual representação matemática e qual estrutura será usada no modelo a ser identificado. Para esse caso, têm-se diversas estruturas possíveis, e não se tem uma forma fechada para determinar qual é a melhor para ser usada. Em (Aguirre, 2015), são abordados alguns dos tipos de modelos que são comumente utilizados para representação de sistemas.

Ao se determinar a estrutura aplicada ao modelo, passa-se ao passo (4), o qual tem por objetivo determinar quais os valores de parâmetros que melhor ajustam os dados coletados do sistema ao modelo proposto para descrever a dinâmica implícita nos

mesmos. Por fim tem-se o passo (5), o qual corresponde à validação do modelo. Nesse passo são desenvolvidas análises de modo a avaliar em diferentes trechos de dados, em relação aos que foram usados para identificação, quão representativo o modelo obtido é para descrever a dinâmica do sistema identificado. Assim, caso os resultados atendam aos requisitos pré-especificados como desejáveis, o procedimento de identificação é finalizado. Caso contrário, deve-se reavaliar um dos passos que sejam necessários até que um modelo satisfatório seja encontrado.

Esse procedimento adotado por [Fortuna et al. \(2007\)](#) para o projeto de sensores virtuais orientados a dados faz referência aos passos da técnica de identificação de sistemas.

## 2.3 Trabalhos Relacionados

O projeto entre a Petrobras e a UFMG vem desde 2010 criando oportunidades para acadêmicos tanto de graduação quanto da pós-graduação desenvolverem seus trabalhos de fim de curso. A partir deles, pretende-se obter contribuições para aprimoramento de ferramentas computacionais que auxiliem de forma benéfica a obtenção de modelos para predição de variáveis do processos de extração de petróleo *offshore*.

Durante o decorrer desse P&D diversos trabalhos foram desenvolvidos, a seguir são apresentados de modo resumido alguns desses trabalhos e suas respectivas contribuições.

O primeiro trabalho foi desenvolvido por [Pankiewicz \(2011\)](#), o qual realizou análises de causalidade entre os sinais de uma curta massa de dados disponibilizada pela Petrobras, que se refere às variáveis de uma determinada plataforma de exploração de petróleo. As análises propostas têm como objetivo determinar se há uma relação dinâmica entre dois ou mais sinais do tipo entrada/saída do processo, determinando dentre esses quais são candidatados a entrada ou saída do modelo dinâmico do processo. Como ferramenta base para análise utilizou-se da função de correlação cruzada (FCC) e da modelagem ARX, a partir dos quais foi determinada uma metodologia para averiguar a relação de causalidade entre sinais.

Dando continuidade ao estudo de causalidade entre os sinais, [Araújo \(2012\)](#) usou de uma massa de dados maior, na qual foram realizadas análises em diferentes contextos dinâmicos. A ferramenta base para as análises também foi a FCC. No entanto, sua ideia foi transformar esse resultado que é gráfico em um número, um índice de correlação, de modo a desenvolver um ferramenta em *Matlab* que faz o estudo de correlação entre sinais automaticamente.

Com o uso dessa ferramenta para análise dos sinais, os demais membros do P&D começaram a trabalhar na identificação de modelos orientados a dados para a estimação da pressão de fundo de poço PT1 ([Teixeira et al., 2012](#)).

Esses modelos foram utilizados por [Castro \(2013\)](#) para o desenvolvimento de sensores virtuais pelo uso de filtros de Kalman *unscented* (FKU). A partir desses filtros, foi

implementado um banco de filtros com o objetivo de obter estimativas mais precisas da PT1, tais algoritmos foram implementados no *Matlab*. Também foram testados diferentes representações matemáticas, para os modelos de processo e observação que compõem o FKU, foram usados de modelos polinomiais NARX (do inglês, *nonlinear autoregressive model with exogenous variables*) e de redes neurais MLP (do inglês, *Multilayer perceptron*).

Trabalhos paralelos ao de [Castro \(2013\)](#) foram desenvolvidos com o objetivo de integrar os sensores virtuais até então desenvolvidos para o ambiente de supervisão dos processos em tempo real da Petrobras, chamado de BR-Optimus.

[Lima \(2013\)](#) realizou a integração de alguns sensores virtuais ao BR-Optimus. Para isso, foi usada a linguagem de programação C++ para o desenvolvimento de DLLs (do inglês, *dynamic link library*) e implementação de interfaces gráficas para validação das saídas dos modelos de forma visual, em que foram apresentadas as variáveis reais e estimadas.

Nesse mesmo contexto, [Matsushita \(2013\)](#) criou DLLs também em linguagem C++ dos códigos em Matlab de cada um dos filtros de Kalman desenvolvidos por [Castro \(2013\)](#) e dos bancos de filtros. O objetivo dessa codificação de códigos em Matlab, que foram desenvolvidos por demais membros do P&D, para DLLs em linguagem C++ foi o de realizar a migração dos laboratórios de pesquisa para o sistema em campo da Petrobras.

Dando continuidade ao projeto de sensores virtuais, [Riccio \(2014\)](#) propôs novas análises, utilizando da mesma metodologia que [Castro \(2013\)](#), mas detendo uma quantidade maior de informações (dados) referentes a diferentes poços de petróleo. Com base nessa nova massa de dados, foi realizada a identificação e validação dos novos modelos.

[Abreu \(2013\)](#) utilizou de técnicas baseadas em redes neurais artificiais (RNA) para identificar sistemas dinâmicos quando se considera os casos em que os dados de identificação não são representativos em relação ao comportamento global do sistema. Foram tratadas duas abordagens, a primeira referente ao uso de uma informação extra no treinamento das RNA, e outra pela aplicação de máquinas de comitê na modelagem de sistemas. Sensores virtuais baseados nessas abordagens foram criados para estimar a PT1.

De maneira geral, os trabalhos desenvolvidos pelos membros do P&D tem como objetivo aprimorar as contribuições obtidas de trabalhos anteriores por meio de novas vertentes de pesquisa, considerando como foco o processo de extração de petróleo. Por fim, vamos citar o trabalho desenvolvido por [Proença \(2015\)](#).

[Proença \(2015\)](#) identificou modelos matemáticos lineares para a estimação da pressão do fundo de poço, sendo esses utilizados para a determinação de filtros de Kalman, e então na composição de bancos de filtros, de modo a obter estimativas mais precisas. Procurando obter uma maior robustez às mudanças dinâmicas encontradas em cada poço, foi investigado o uso da abordagem baseada em estimação dual de estados e

---

parâmetros, possibilitando assim a estimação *online* para atualização de alguns parâmetros dos modelos obtidos. Para essa abordagem, foi usado o algoritmo de mínimos quadrados recursivos (MQR), apresentado em [Aguirre \(2015\)](#), para o qual o fator de esquecimento foi determinado com um valor constante. No entanto, seus resultados mostraram que a abordagem de resintonia proposta não compõe uma metodologia vantajosa, devido à baixa persistência de excitação nos dados. Isso está relacionado, ao fato desses dados corresponderem em maior parte do tempo ao processo operando em condições em regime estacionário, o que implica em pouca informação sobre a dinâmica do sistema.



# Identificação de Sistemas e Filtragem: uma Visão Geral

## 3.1 Introdução

Neste capítulo é apresentada uma revisão sobre as principais ferramentas relacionadas ao desenvolvimento desta dissertação. Na Figura 3.1 tem-se um diagrama representativo com as principais áreas de pesquisas estudadas e métodos utilizados para o desenvolvimento e análise de sensores virtuais.

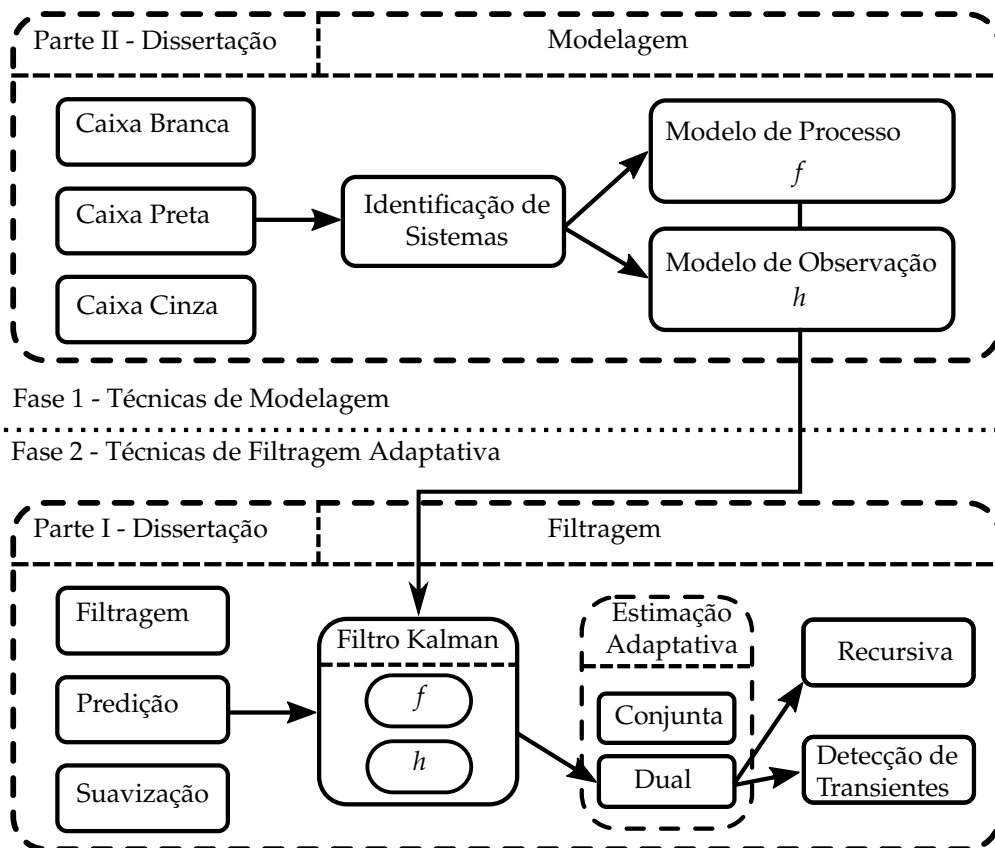


Figura 3.1: Diagrama geral para desenvolvimento e análise de sensores virtuais, levando em consideração a área de pesquisa e técnicas utilizadas em cada uma das fases.

A Fase 1, mostrada na Figura 3.1, corresponde ao uso de técnicas para obtenção de modelos que descrevam o comportamento dinâmico do sistema em estudo. Dentre as categorias de modelagem apresentadas, utiliza-se a modelagem caixa preta. Na Fase 2, os modelos de processo e observação obtidos na primeira fase são usados para compor o filtro de Kalman (FK) como uma ferramenta de predição. Pelo uso de técnicas de filtragem adaptativa, os modelos são atualizados em tempo de execução pelo uso da abordagem de estimação dual de estados e parâmetros. Assim, pretende-se atribuir certa robustez as estimativas resultantes do FK para o caso em que os parâmetros do sistema variam. Essas fases incorporam os temas tratados no desenvolvimento deste trabalho, os quais foram descritos ao final da Seção 1.2 e discriminados como partes I e II.

O restante desse capítulo é organizado como se segue. Na Seção 3.2 é realizada uma breve descrição sobre as três categorias de modelagem, caixa branca, preta e cinza, e de alguns trabalhos da literatura que utilizam das mesmas para desenvolver projetos em processos de extração de petróleo. Em seguida, são apresentadas as técnicas de identificação de sistemas que correspondem à categoria de interesse a ser tratada neste trabalho. Na Seção 3.3 é apresentado o problema de filtragem considerando como ferramenta de predição o FK para estimação de estados. Para abordar a ideia de aquisição de robustez às mudanças dinâmicas do processo de extração de petróleo ao longo do tempo, é tratado o caso em que os estados e parâmetros são estimados de forma simultânea por meio da abordagem dual. Para esse tipo de abordagem é realizada uma descrição geral de como métodos recursivos ou em batelada associados com técnicas para detecção de transientes podem ser utilizados para se atualizar os modelos em tempo de execução.

## 3.2 Modelagem

Modelagem matemática é a área do conhecimento que trata de técnicas objetivando abstrair matematicamente, mesmo que de forma aproximada, o comportamento apresentado em sistemas reais (Garcia, 2005). Entre as várias técnicas de modelagem, têm-se a modelagem caixa branca, caixa preta e caixa cinza.

Segundo Aguirre (2015), a modelagem caixa branca corresponde à técnica para a qual é necessário conhecer bem os princípios químicos e físicos do sistema que se deseja modelar, ou seja, as relações matemáticas que explicam os fenômenos envolvidos. A denominação caixa branca pode muitas vezes ser referenciada como modelagem pela física do processo ou fenomenológica. Contudo, devido à falta de conhecimento suficiente sobre os fenômenos do sistema, ou o tempo demandando e complexidade para obtenção de um modelo, o uso desse tipo de modelagem torna-se inadequado.

Com base nesse tipo de modelagem, têm-se na literatura alguns trabalhos desenvolvidos, sendo considerado para citação apenas os relacionados ao processo de produção de petróleo. Em (Leal, 2006), foi desenvolvido um modelo para descrever o comporta-

mento dinâmico do mecanismo de elevação artificial por *gas lift*. A partir desse modelo, o autor propõe estudos de modo a comparar em quais situações o mecanismo por *gas lift* apresenta desempenho satisfatório comparado com o método de elevação por uma bomba multifásica. Xaud (2014), por sua vez, cita em seu trabalho modelos que foram desenvolvidos por outros autores, e utiliza de um dentre esses modelos apresentados para estudo da aplicação de métodos de controle adaptativo para manipular a injeção da vazão de *gas lift*, com o objetivo de maximar a produção de óleo em regime permanente no poço em estudo. Os sensores virtuais criados por base nesses princípios são nomeados como *sensores orientados a modelos* (Kadlec et al., 2009).

Para o caso em que a obtenção de modelos pela técnica caixa branca torna-se impraticável, tem-se como opção a modelagem caixa preta, a qual também pode ser denominada como modelagem empírica. Nessa técnica nenhum conhecimento prévio sobre os fenômenos que regem o sistema é necessário. Por meio do uso de técnicas de identificação de sistemas, objetiva-se criar modelos que descrevam o comportamento de um sistema a partir da relação de causa e efeito entre variáveis de entrada e de saída coletadas do mesmo. Essa área de pesquisa é de interesse neste trabalho, e será discutida à frente. Os sensores virtuais que se distinguem por esse tipo de técnica são nomeados como *sensores orientados a dados*.

Como exemplo de trabalhos baseados em técnicas de modelagem caixa preta, têm-se os desenvolvidos por Silva (2007) e Torres (2012). Em (Silva, 2007), faz-se o estudo para estimação da vazão de gás em poços que usam da técnica de elevação artificial denominada como *plunger lift*, a qual consiste de um pistão livre que atua como um manipulador mecânico sobre os fluidos produzidos. Essa vazão a ser estimada tem suas medidas coletadas em um vaso separador de teste da plataforma de produção de petróleo. Para o desenvolvimento dessa análise da vazão de gás, são levantados modelos caixa preta, tendo os dados da vazão de saída de gás do vaso separador de teste, o qual se deseja estimar, e o sinal de uma válvula controladora de pressão como entrada. Já em (Torres, 2012), é realizado o estudo de desempenho produtivo do poço de petróleo, no qual são usados métodos para elevação de seus fluidos por meio do sistema de bombeamento mecânico. Assim, faz-se a identificação de um modelo dinâmico para um sistema de bombeamento mecânico, e em seguida um controlador adaptativo é proposto de modo a atribuir certa robustez ao sistema de controle.

Outra forma para o desenvolvimento de modelos corresponde a utilizar da combinação dos métodos caixa branca e preta. Aplicam-se técnicas de identificação para realizar a estimação de parâmetros em modelos que tenham sido gerados pela conhecimento matemático das equações dos fenômenos físicos e/ou químicos do sistema em estudo (Garcia, 2005). Esse tipo de técnica é denominada como caixa cinza.

Para esse tipo de técnica, os sensores virtuais são considerados orientados a dados, pelo fato de modelos também poderem ser identificados via caixa preta por adição de uma informação auxiliar, que não se encontre na massa de dados dinâmicos utilizada para identificação. O desenvolvimento desse tipo de técnica, tem-se tornado um dos

grandes desafios na atualidade em identificação de sistemas (Aguirre, 2015).

Considerando esse tipo de modelagem, também foram encontrados trabalhos desenvolvidos nessa linha de pesquisa. No trabalho de Gerevini (2014), foram analisados poços com elevação artificial por *gas lift*, em que usou-se de modelos caixa cinza para reproduzir a dinâmica oscilatória conhecida como golfada, a qual gera queda na produção. Com base nesses modelos, foi proposta uma estratégia de controle de modo a inibir a ocorrência dessas golfadas na medida resultante para controle, procurando assim otimizar a produção. Em (Abreu, 2013), é desenvolvido um modelo caixa cinza para estimação da pressão de fundo de poço de petróleo, em que se utilizam redes neurais MLP com o uso de informação auxiliar na fase de treinamento.

### 3.2.1 Identificação de Sistemas

O campo de identificação de sistemas visa a estudar métodos para determinação de modelos matemáticos que sejam capazes de explicar o comportamento dinâmico implícito em dados de entrada e saída, referentes a um determinado sistema (Ljung, 1998). Por isso, faz-se necessário que os dados coletados para identificação possuam informação dinâmica relevante. Essa característica é obtida, quando possível, por meio do projeto de testes dinâmicos adequados para o sistema, sendo essa a primeira etapa do problema de identificação.

Para uma melhor compreensão do problema de identificação de sistemas, as principais etapas podem ser descritas por 4 itens: (i) testes dinâmicos, (ii) seleção da estrutura de modelos, (iii) estimação de parâmetros e (iv) validação de modelos (Aguirre, 2015).

Considerando as duas partes em que está dividida a dissertação, a Parte I objetiva atribuir robustez a sensores para predição da pressão de fundo de poço, os quais foram previamente definidos em trabalhos realizados pelo grupo de pesquisa. Para a Parte II, pretende-se analisar os dados coletados de poços de extração de petróleo para criar sensores virtuais considerando a estimação da vazão de óleo de forma direta.

Para cada uma dessas partes é possível determinar dentre as etapas de identificação quais possuem maior relevância, ou seja, quais dessas são usadas para aplicação. Iniciando pela Parte II, referente a Fase 1 da Figura 3.1 e presente Seção 3.2 em discussão, por os dados serem coletados em um separador de testes em momentos alternados de aquisição, uma maior relevância é atribuída a etapa (i). Essa importância pode ser explicada devido a necessidade de executar de forma adequada a análise desses novos dados, de modo a classificá-los como válidos ou não para obtenção de modelos preditivos. Ao considerar a Parte I, referente às técnicas apresentadas na Seção 3.3 e Fase 2 da Figura 3.1, têm-se que uma maior ênfase é atribuída as etapas (iii) e (iv) de identificação. Isso, pelo fato de serem usados modelos para a PT1 previamente obtidos em (Proença, 2015), e ter como objetivo atualizar de forma *online* os parâmetros desses modelos que são usados na composição de sensores virtuais. Assim, estudos sobre técnicas de estimação de parâmetros e, conseqüentemente, a avaliação desses modelos

atualizados são os protagonistas nessa parte do trabalho. No entanto, nesta Subseção todas as etapas de identificação serão discutidas, mesmo que seja brevemente, de modo a oferecer uma melhor compreensão sobre como cada uma dessas etapas foram estabelecidas.

### 3.2.1.1 Testes dinâmicos

A coleta adequada dos dados do sistema a ser modelado é de fundamental importância, já que é a partir desses dados que os modelos preditivos obtidos por meio das técnicas aqui tratadas são desenvolvidos. Dessa maneira, a definição adequada do projeto de testes torna-se essencial, no qual são determinados *a priori* os pontos de operação de interesse em que o sistema será excitado e o tipo de sinal usado para esse fim.

Quando o sistema de interesse para identificação pode ser expresso como linear, o projeto do sinal de testes tem por objetivo excitar uma ampla faixa de frequências do sistema, gerando uma saída com informação dinâmica significativa. Um sinal de simples implementação prática e que produz bons resultados é o sinal binário pseudoaleatório (PRBS do inglês, *pseudo random binary signal*), que pode ser adaptado para testes em sistemas não lineares, por meio da variação de sua amplitude (Aguirre, 2015).

Para situações em que o projeto de testes não é possível, como exemplo, no uso de dados históricos para identificação de modelos, tem-se a necessidade de se realizar uma avaliação adequada desses dados para fins de identificação. Isso está relacionado ao fato de que, para obter modelos matemáticos que descrevam a dinâmica entre duas variáveis de um sistema (entrada e saída), é preciso que essas sejam correlacionadas. Além disso, ao usar de dados históricos para identificação, os quais são coletados em maior parte do tempo para condições normais de operação do processo têm-se janelas de dados que não possuem informação dinâmica significativa do sistema. Esse tipo de contexto é comumente encontrado em processos de extração de petróleo.

No caso em que o objetivo é obter modelos para a vazão de óleo produzido, torna-se necessário avaliar se há correlação significativa entre essa variável e as demais que são candidatas a entrada do modelo. A ferramenta utilizada para esse propósito é a função de correlação cruzada (FCC). A FCC é usada para avaliar a similaridade temporal e relação de causa e efeito entre duas variáveis candidatas a compor o modelo de estimação (Aguirre, 2015).

Considere dois sinais estacionários  $y_k$  e  $u_k$ , para os quais sua FCC mede a dependência temporal entre  $u$  e medidas deslocadas de  $y$  por  $\tau$  atrasos. Essa função é definida por (Kay, 2006):

$$r_{uy,\tau} = E[u_k y_{k+\tau}], \quad (3.1)$$

em que  $E[\cdot]$  é a esperança matemática.

Ao considerar que os sinais em análise correspondem a um processo ergódico, de modo a substituir o operador de esperança  $E[\cdot]$  pela média temporal, a FCC pode ser estimada por um número finito de amostras  $N$  para duas variáveis  $u$  e  $y$  com média nula:

$$\hat{r}_{uy,\tau} = \begin{cases} \frac{1}{N} \sum_{i=1}^{N-\tau} u_i y_{i+\tau}, & \tau = 0, 1, \dots, N-1, \\ \frac{1}{N} \sum_{i=1}^{N+\tau} y_i u_{i-\tau}, & \tau = 0, -1, \dots, -N+1. \end{cases} \quad (3.2)$$

Segundo [Aguirre \(2015\)](#), a estimativa  $\hat{r}_{uy,\tau}$  é nomeada como FCC amostral. Trata-se de uma estimativa consistente da FCC, já que elas se aproximam do valor verdadeiro a medida que o número de amostras  $N \rightarrow \infty$ .

Após obtidos os valores da FCC dos sinais de interesse para análise, é necessário quantificar quão significativa é a correlação entre tais sinais analisados. Um conceito que é aplicado a esse tipo de análise é definido como intervalo de confiança, sendo considerado que os sinais  $u_k$  e  $y_k$  são descorrelacionados com 95% de confiança, para o caso em que a FCC para os atrasos  $\tau$  encontra-se dentro do intervalo dado por:

$$\frac{-1,96}{\sqrt{N}} \leq \rho_{uy,\tau} \leq \frac{1,96}{\sqrt{N}}, \quad (3.3)$$

em que  $\rho_{uy,\tau} = \hat{r}_{uy,\tau} / \sigma_u \sigma_y$  é a FCC normalizada, sendo  $\sigma$  referente ao desvio padrão. Logo, para o caso em que a FCC encontra-se fora do intervalo de confiança para determinado atraso  $\tau$ , pode-se dizer que nesse atraso há uma alta probabilidade de que os sinais em análise sejam correlacionados.

### 3.2.1.2 Seleção da estrutura de modelos

A escolha pela estrutura a ser utilizada na determinação de modelos não é uma tarefa trivial. Em muitos casos o problema para se determinar uma boa representação para um determinado sistema é realizado por tentativa e erro ([Aguirre, 2015](#)).

Na Seção 1.4 os modelos tratados são os polinomiais do tipo ARX, os quais foram obtidos em ([Proença, 2015](#)) para estimar a pressão de fundo de poço, e usados nos estudos da parte I dessa dissertação.

Após a escolha da representação a ser usada, passa-se para a determinação da estrutura, em que se deve escolher de forma adequada a quantidade dos termos de regressão a serem estabelecidos para cada uma das variáveis determinadas a comporem o modelo. Uma ferramenta que pode ser utilizada para esse fim, é o critério de informação de Akaike (AIC) ([Aguirre, 2015](#), Cap. 12).

### 3.2.1.3 Estimação de parâmetros

Esta etapa consiste na atribuição de valores numéricos aos parâmetros dos termos que constituem o modelo. Dentre os algoritmos usados para se estimar parâmetros, tem-se o de mínimos quadrados (MQ), o qual é embasado em uma álgebra relativa-

mente simples para seu entendimento, sendo esse um dos motivos por que o tornou um dos mais populares algoritmos (Aguirre, 2015).

Quando todos os dados para estimação dos parâmetros são disponibilizados *a priori*, pode-se usar do MQ em batelada. Para isso, considere o modelo dinâmico descrito na equação (1.4), o qual será reescrito na forma matricial dada por

$$Z = \Psi\theta + \Xi, \quad (3.4)$$

em que  $Z \triangleq [z_k, z_{k-1}, \dots, z_{k+1-N}]^T \in \mathbb{R}^N$  é o vetor com medições da saída  $z_k$ ,  $\Psi \triangleq [\psi_{zu,k-1}^T; \dots; \psi_{zu,k-N}^T] \in \mathbb{R}^{N \times n_\theta}$  é a matriz de regressores e  $\psi_{zu,k-i}$  a  $i$ -ésima linha de  $\Psi$  (sendo que  $\psi_{zu,k-i}$  é um vetor coluna,  $\psi_{zu,k-i} \in \mathbb{R}^{n_\theta}$  conforme especificado na Subseção 1.4.2),  $\theta \in \mathbb{R}^{n_\theta}$  são os parâmetros de ajuste e  $\Xi \triangleq [e_k, e_{k-1}, \dots, e_{k-N}]^T \in \mathbb{R}^N$  é o vetor do erro de modelagem (resíduos)  $e_k$ .

A estimação dos parâmetros do modelo (3.4) pelo algoritmo MQ em batelada é dada por

$$\hat{\theta} = [\Psi^T \Psi]^{-1} [\Psi^T Z], \quad (3.5)$$

a qual determina os parâmetros pela minimização da função de custo referente ao somatório do quadrado dos erros de modelagem.

Ao contrário do MQ em batelada, o algoritmo de mínimos quadrados recursivos realiza a estimação de seus parâmetros em tempo de execução ao passo que os dados são coletados e disponibilizados. Para isso é necessário que esses dados sejam persistentemente excitantes (Aguirre, 2015).

Para estimação de parâmetros invariantes no tempo, considerando o processamento *online*, tem-se que os algoritmos de mínimos quadrados recursivos convencional (MQRC) são vastamente usados. Esse estimador é descrito pelas seguintes equações

$$K_k = \frac{P_{k-1} \psi_k}{\psi_k^T P_{k-1} \psi_k + 1}, \quad (3.6)$$

$$\hat{\theta}_k = \hat{\theta}_{k-1} + K_k [y_k - \psi_k^T \hat{\theta}_k], \quad (3.7)$$

$$P_k = P_{k-1} - \frac{P_{k-1} \psi_k \psi_k^T P_{k-1}}{\psi_k^T P_{k-1} \psi_k + 1}, \quad (3.8)$$

onde  $K_k$  é o ganho de Kalman e  $P_k$  a matriz de covariância calculada na iteração  $k$  para o parâmetro  $\hat{\theta}_k$ .

### 3.2.1.4 Validação de modelos

Esta é a última etapa do procedimento de identificação de sistemas, em que se tem o modelo resultante obtido para validação. A partir desse ponto é necessário avaliar tal modelo com relação a sua capacidade de predição. Com esse fim, neste trabalho, são utilizados dois meios de avaliação, um qualitativo em que se faz a comparação

gráfica entre a curva do sinal coletado do sistema com a curva estimada produzida pelo modelo; e uma avaliação quantitativa por meio de métodos estatísticos.

Para a análise gráfica é realizada uma comparação dos sinais tanto em relação à amplitude apresentada quanto devido a seu comportamento dinâmico. A semelhança entre esses sinais é quantificada por meio de um método para avaliação das estimativas obtidas, para isso adotou-se o erro percentual absoluto médio

$$\text{EPAM} = \frac{1}{N} \sum_{k=1}^N \frac{|z_k - \hat{z}_k|}{|z_k|} (100), \quad (3.9)$$

em que  $z_k$  é a saída medida,  $\hat{z}_k = \psi_k^T \hat{\theta}_{k-1}$  é a saída estimada e  $N$  é a quantidade de amostras para análise.

### 3.2.1.5 Persistência de excitação em conjunto de dados

Têm-se duas características essenciais para obtenção de bons modelos dinâmicos preditivos. Uma das características refere-se à existência de correlação nos dados coletados, de modo que a relação entre sinais como entrada/saída seja possível. A segunda característica, consiste no fato de que informação relevante sobre a dinâmica do sistema de interesse esteja presente nos dados de identificação.

Para o caso em que o projeto do sinal de testes é uma tarefa factível, tal sinal deve excitar todos os modos dinâmicos de interesse, de forma que se tenha um sinal com informação dinâmica relevante do sistema durante o período de identificação. Esse sinal de entrada externa é responsável pela característica de excitação persistente nos dados.

No caso em que apenas dados históricos são usados para identificação, ou seja, não é realizado *a priori* o projeto do sinal de entrada para testes, torna-se necessário que esses dados sejam analisados para determinar se há ou não tal característica excitante. A análise de dados históricos é necessária devido esses comumente serem referentes a operação normal do processo, cenário o qual não se tem a garantia de que durante todo o tempo de aquisição os dados coletados possuam informação dinâmica relevante.

Assim, para o caso em que é possível determinar o sinal de entrada a ser aplicado no sistema de interesse, esse sinal deve ser projetado de modo que ele contenha características excitantes adequadas. Já para o caso em que utiliza-se de dados históricos, a atenção passa a ser dada ao sinal de saída a ser estimado pelo modelo, podendo dessa maneira selecionar quais janelas de dados que possuem informação relevante para identificação.

Essa presença de excitação persistente também está relacionada com a eficiência na convergência dos parâmetros estimados na etapa (iv) para identificação de sistemas. Assim, caso não se tenha excitação nos dados de identificação, a estimação de parâmetros para o modelo dinâmico pode produzir valores inadequados.

Dessa maneira, nota-se que além da correlação nos dados usados para identificação, os mesmos devem ser persistentemente excitantes, pelo fato de ambas características estarem diretamente relacionadas com a capacidade de predição do modelo dinâmico obtido. Assim, desenvolver esse tipo de análise em dados usados para identificação corresponde a uma tarefa valiosa.

### 3.2.2 Modelos de Processo e Observação

Neste trabalho as etapas que constituem a técnica de identificação de sistemas são usadas para obtenção de modelos, por exemplo, os obtidos em (Proença, 2015) para predição da pressão de fundo de poço PT1. Por meio desses modelos, tem-se como objetivo compor sensores virtuais baseados em filtros de Kalman (FK), Figura 3.1, os quais necessitam de dois tipos de modelos preditivos, um denominado como modelo de processo discriminado pela letra  $f$  e outro de observação discriminado pela letra  $h$ . Esses modelos foram identificados na representação ARX (1.4).

O modelo de processo  $f$  obtido (3.10) tem por finalidade prever a variável de saída desejada a ser estimada, PT1. E como variáveis de entrada são usadas as identificadas como adequadas a comporem determinado modelo durante o procedimento de identificação de sistemas.

Dessa maneira, o modelo previamente especificado para o poço R da Petrobras, escolhido para estudos, é dado como,

$$\begin{aligned} z_k = & 1,5634 z_{k-1} - 0,5715 z_{k-2} + 0,1174 u_{1,k-1} \\ & - 0,0696 u_{1,k-2} - 0,0176 u_{1,k-5} - 0,0502 u_{1,k-7} \\ & + 0,0158 u_{1,k-9} - 0,000038 u_{2,k-7} + 0,8482, \end{aligned} \quad (3.10)$$

em que  $u_{1,k}$  e  $u_{2,k}$  são respectivamente a temperatura a montante do choke de produção TT3 e vazão de *gas lift* FT4, e para esse caso a saída  $z_k$  é a pressão PT1.

O modelo de observação  $h$  desenvolvido (3.11) tem por finalidade prever uma variável auxiliar, a qual servirá como medida de correção da predição da PT1 obtida pelo FK. A variável estimada por esse modelo  $h$  deve ser uma variável do sistema que esteja bem correlacionada com a PT1, de modo que a partir dessa medida e de outras realizadas ao longo do processo seja possível se estimar tal variável.

O modelo de regressão linear a ser utilizado para descrever o modelo de observação, é determinado por uma saída  $z_k$  que é dada pela pressão a montante da válvula choke de produção PT3 e expresso como

$$\begin{aligned} z_k = & 0,7669 z_{k-1} - 0,03 z_{k-2} + 0,059 u_{1,k-1} \\ & + 0,029 u_{1,k-5} - 0,109 u_{1,k-9} + 0,106 u_{2,k-1} \\ & - 0,117 u_{2,k-2} + 0,0149 u_{2,k-9} + 4,23, \end{aligned} \quad (3.11)$$

em que  $u_{1,k}$  e  $u_{2,k}$  são respectivamente a PT1 e a pressão a montante da válvula SDV de produção PT3a.

Ambos os modelos usados são do tipo IIR (do inglês, *infinite impulse response*), em que têm-se termos auto regressivos da variável de interesse usados na composição desses modelos.

### 3.3 Filtragem

Quando objetiva-se obter estimativas *online* de variáveis que não podem ser diretamente medidas, de parâmetros de modelos ou para eliminar atrasos de medição, é que têm-se estudado técnicas de estimação de estados. Dentre as varias encontradas na literatura, tem-se as técnicas de filtragem (De Assis e Maciel Filho, 2000).

O termo “filtro”, que é comumente usado para descrever uma ferramenta física de separação e/ou remoção de impurezas de uma substância, como em misturas de gás, líquido e sólido, passou a ser usado para tratar de estimadores. Esse conceito foi abordado na década de 30 e 40, o qual foi estendido para considerar a separação de sinais dos ruídos em dados (Grewal e Andrews, 2001).

Esse ruído que sobrepõe o sinal de interesse, comumente pode corresponder desde erro nos sensores de medição até a interferência de sinais adversos do ambiente em que é realizada a coleta dos dados. Sinais contaminados tendem a prejudicar as estimativas resultantes dos modelos matemáticos usados para descrever o comportamento do sistema identificado. Para tratar esse tipo de situação encontrada pelo uso de dados contaminados para estimação, os problemas de filtragem podem ser classificados em três ferramentas básicas de estimação: filtragem, predição e suavização (Anderson e Moore, 1979).

A filtragem faz referência ao processamento do sinal, para o qual usa-se de medidas para recuperar o sinal no instante atual a partir de medidas obtidas em tempos anteriores até o tempo atual que se deseja estimar. A predição, também denominada como extrapolação ou previsão, tem como objetivo estimar o sinal desejado em tempos consequentes à última medida coletada do sistema. Suavização, também conhecida como interpolação, difere no fato de que, para obter a estimativa de um sinal em um determinado tempo, medidas que sejam referentes a tempos posteriores ao do sinal que se deseja estimar podem ser utilizadas. Nesse caso, o sinal é estimado ao longo do tempo, desde a medida inicial até se alcançar a última medida do sistema.

Para situações em que se deseja trabalhar com filtragem ou predição, consideram-se normalmente modos de aplicação para estimação *online*. Já para o problema de suavização comumente considera-se trabalhar com estimação *offline*, podendo esse problema tratar de processos *online* desde que atrasos entre a obtenção de medidas do sistema e sua estimativa não seja considerado como um fator de relevância. Assim, melhores estimativas podem ser alcançadas pelo suavizador, ao se usar de dados

posteriores do qual se deseja estimar (Kalman, 1960). Uma representação gráfica dessas ferramentas são mostradas na Figura 3.2.




Figura 3.2: Ilustração das três ferramentas de estimação relacionadas ao problema de filtragem. Essas são mostradas com relação ao tempo e amostras (medidas) de interesse para estimação. (•) são as medidas coletadas de um tempo inicial até o instante atual. (—) suavizador. (•) filtro. (—) preditor.

Entre as diversas técnicas de filtragem na literatura, nesta dissertação, determinou-se o uso do FK como uma ferramenta de predição para desenvolver e analisar sensores virtuais para estimação de variáveis do processo de extração de petróleo.

### 3.3.1 Filtro de Kalman

O FK é um estimador de estados para sistemas dinâmicos lineares (Kalman, 1960). Esse filtro é composto por uma estrutura predição-correção.

Para sistemas não lineares outros algoritmos baseados no FK têm sido propostos. Um desses algoritmos é o filtro de Kalman estendido (FKE), o qual realiza uma linearização analítica do modelo que descreve o sistema em torno do estado atual de interesse (Aguirre, 2015). Porém, o FKE possui sensibilidade para casos em que o sistema em estudo seja fortemente não linear, estando essa relacionada à determinação das condições iniciais e à sintonia das matrizes de covariância de ruído. Com isso, surgiu como alternativa o filtro de Kalman *unscented* (FKU), que emprega uma linearização estatística. Além disso, têm-se o cálculo da propagação temporal da média e da matriz de covariância dos estados do sistemas não linear de modo mais eficiente, resultando em um melhor desempenho do FKU em relação ao FKE (Teixeira et al., 2009).

Como os modelos tratados para identificação do sistema de extração de petróleo são lineares do tipo ARX, este trabalho usa o FK como estimador de estado. Desse modo, têm-se que  $f$  e  $h$  da Subseção 1.4.1 correspondem a funções lineares, de modo que a descrição do sistema dinâmico pelas equações (1.1)-(1.2) pode ser reescrita em espaço de estados como

$$x_k = A_{k-1} x_{k-1} + B_{k-1} u_{k-1}^f + w_{k-1}, \quad (3.12)$$

$$y_k = C_k x_k + D_k u_k^h + v_k, \quad (3.13)$$

em que  $A_{k-1} \in \mathbb{R}^{n \times n}$ ,  $B_{k-1} \in \mathbb{R}^{n \times p_f}$ ,  $C_k \in \mathbb{R}^{m \times n}$  e  $D_k \in \mathbb{R}^{n \times p_h}$  são assumidamente conhecidos durante solução do problema de identificação de sistemas. Assume-se que  $w_{k-1}$  e  $v_k$  são



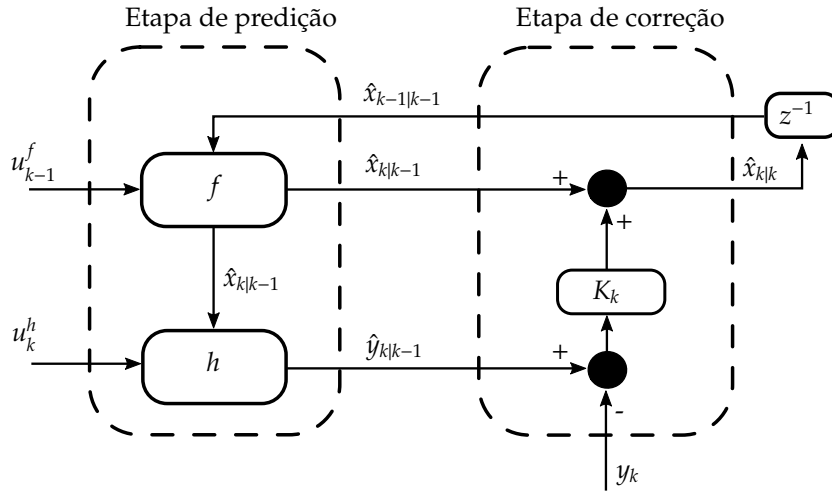


Figura 3.3: Esquema do algoritmo do Filtro de Kalman. Baseado em: (Herrera, 2012)

Como mostrado na Figura 3.3, o FK é composto de duas etapas: predição e correção. Para o presente trabalho em que pretende-se estimar a pressão de fundo de poço do processo de extração *offshore* por meio do FK, essas etapas são relatadas a seguir. Na etapa de predição é estimado o vetor de estados  $\hat{x}_{k|k-1}$  por meio do modelo de processo  $f$  (3.10), o qual neste trabalho corresponde à estimativa da variável referente à pressão de fundo PT1. Também nessa etapa, é realizada a estimação da variável de observação  $\hat{y}_{k|k-1}$  que corresponde neste trabalho à PT3, a qual é obtida pela aplicação do vetor de estados estimados  $\hat{x}_{k|k-1}$  (PT1) e outras variáveis  $u_k^h$  (PT3a) medidas do sistema a um modelo de observação  $h$  (3.11). Essa etapa é descrita por

$$\hat{x}_{k|k-1} = A_{k-1}\hat{x}_{k-1|k-1} + B_{k-1}u_{k-1}^f, \quad (3.14)$$

$$P_{k|k-1}^{xx} = A_{k-1}P_{k-1|k-1}^{xx}A_{k-1}^T + Q_{k-1} \quad (3.15)$$

$$\hat{y}_{k|k-1} = C_k\hat{x}_{k|k-1} + D_k u_k^h, \quad (3.16)$$

$$P_{k|k-1}^{yy} = C_k P_{k|k-1}^{xx} C_k^T + R_k, \quad (3.17)$$

$$P_{k|k-1}^{xy} = P_{k|k-1}^{xx} C_k^T, \quad (3.18)$$

em que  $P_{k|k-1}^{xx} = E[(x_k - \hat{x}_{k|k-1})(x_k - \hat{x}_{k|k-1})^T]$ ,  $P_{k|k-1}^{yy} = E[(y_k - \hat{y}_{k|k-1})(y_k - \hat{y}_{k|k-1})^T]$  e  $P_{k|k-1}^{xy} = E[(x_k - \hat{x}_{k|k-1})(y_k - \hat{y}_{k|k-1})^T]$ . Os valores iniciais para  $\hat{x}_{0|0}$  e  $P_{0|0}^{xx}$  são assumidamente conhecidos.

Na etapa de correção, empregam-se essas estimativas  $\hat{x}_{k|k-1}$  e  $\hat{y}_{k|k-1}$  em conjunto com a variável de observação  $y_k$  PT3, de modo a obter uma estimativa do vetor de estados

$\hat{x}_{k|k}$  PT1 atualizada. As equações que descrevem essa etapa são dadas por

$$K_k = P_{k|k-1}^{xy} (P_{k|k-1}^{yy})^{-1}, \quad (3.19)$$

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k (y_k - \hat{y}_{k|k-1}), \quad (3.20)$$

$$P_{k|k}^{xx} = P_{k|k-1}^{xx} - K_k P_{k|k-1}^{yy} K_k^T, \quad (3.21)$$

em que  $P_{k|k}^{xx} = E[(x_k - \hat{x}_{k|k})(x_k - \hat{x}_{k|k})^T]$  e  $K_k \in \mathbb{R}^{n \times m}$  são respectivamente as matrizes de covariância do erro de estimação e o ganho de Kalman. A notação usada é interpretada como, para  $\hat{x}_{k|l}$  têm-se a estimação de  $x_k$  no tempo  $k$  baseando-se em informações disponíveis até e incluso o tempo  $l$ .

### 3.3.2 Estimação de Parâmetros Variantes no Tempo

Quando se objetiva identificar sistemas reais por meio de modelos matemáticos, variadas representações podem ser usadas dependendo do tipo de informação que se deseja abstrair do processo dinâmico de interesse. Dentre as diversas representações que englobam a família de modelos lineares a não lineares, em muitos casos é possível por meio dos modelos mais simples representar o comportamento dinâmico dominante do sistema real de interesse a ser identificado. Por exemplo, sistemas não lineares podem muitas vezes ser tratados como lineares variantes no tempo ou a parâmetros variantes (De Araújo, 2006).

Na prática pode-se considerar que praticamente todo sistema dinâmico pode ser descrito por um modelo a parâmetros variantes. Essa afirmação refere-se ao fato de alterações no comportamento dinâmico de uma gama de sistemas práticos ocorrerem devido a fatores que podem estar relacionados desde o ambiente, instrumento e/ou envelhecimento do processo. Esse tipo de análise se enquadra em diferentes contextos, por exemplo nos citados a seguir. Ao se trabalhar com circuitos elétricos resistivos, sua resistência pode sofrer variação com a temperatura, o que gera alteração no comportamento dinâmico do mesmo. No caso do processo de exploração de petróleo, com o passar do tempo, a dinâmica interna do poço de produção varia sua pressão, assim, ao passo que o poço envelhece a dinâmica do mesmo é alterada.

É entre esses e diversos outros problemas em processos industriais que o projeto de sensores virtuais tem se tornado cada vez mais interessante. Pode-se, por meio desses sensores, alcançar estimativas dos estados do processo ainda mais precisas, à medida que seja considerado que os parâmetros dos modelos preditivos estão sujeitos a sofrerem alterações ao longo do tempo.

A partir de dados de entrada e saída, e dos modelos de processo e observação descritos no espaço de estados, é possível estimar os estados de sistemas dinâmicos por meio do FK. Em alguns casos, alguns dos parâmetros desses modelos são desconhecidos ou variam com o tempo de forma que devem ser estimados concomitantemente aos estados. Para tratar do problema de estimação de estados e parâmetros de sistemas

dinâmicos, a literatura apresenta dois métodos de estimação: a conjunta e a dual. Ambos os métodos abordam a ideia de se atribuir robustez ao FK pela atualização de seus modelos em tempo de execução.

A estimação conjunta de estados e parâmetros trata da estimação de ambos em uma única etapa, por meio da definição de um vetor de estados aumentado, que inclui os parâmetros.

Tendo como base os processos relacionados à produção de petróleo, foram encontrados na literatura alguns trabalhos que utilizam desse método de estimação conjunta. Por exemplo, em (Mahdianfar et al., 2013), é apresentado o problema de perfuração em poços *offshore*, o qual usualmente possui seus sistemas de controle automático de perfuração baseados em modelos que estimam a pressão e vazão no fundo do poço em perfuração. O caso tratado utiliza de um sistema de controle em malha fechada, o qual atua na pressão de perfuração. Um modelo hidráulico, caixa branca, para esse sistema de gerenciamento da pressão de perfuração é derivado a partir do balanço de massa e quantidade de movimento, o qual fornece a pressão e vazão no poço durante a operação de perfuração. Porém, vários parâmetros desse modelo são incertos, de modo que a atualização em tempo de execução desse modelo torna-se uma tarefa valiosa. Com esse fim, é projetado um FKU para estimação conjunta dos estados e parâmetros desconhecidos para esse sistema, tendo como base apenas medidas do processo que são coletadas na superfície. Já em (Nikoofard et al., 2015), o mesmo problema referente à perfuração de poços *offshore* é tratado, porém, considerando uma abordagem alternativa de operação conhecida como perfuração sub balanceada, mantendo a atuação na pressão de perfuração. Essa nova abordagem de operação difere da apresentada por eles como típica, em relação às configurações dos valores das pressões a serem controladas ao longo do poço em perfuração. Para esse tipo de operação um modelo multifásico descrevendo duas fases de fluxos, gás e líquido, é usado. A partir desse modelo implementou-se o FKU e FKE com o método de estimação conjunta de estados e parâmetros, para comparação entre os filtros aplicados a um simulador industrial de alta fidelidade usado para simulação dinâmica da produção de óleo e gás.

Na abordagem dual, o modelo de processo e de evolução dos parâmetros são tratados separadamente em dois estimadores distintos. Segundo Nelson (2000), a abordagem dual atenua alguns problemas de divergência que ocorrem na conjunta, por meio do desacoplamento entre a estimação dos estados e parâmetros. Neste trabalho, escolhe-se o método dual pela possibilidade de optar por não estimar os parâmetros em alguns intervalos de tempo.

O trabalho de Proença (2015) é um exemplo que trata desse tipo de método dual em processos de produção de petróleo para atualizar os modelos que compõem o FK para estimação da pressão de fundo de poço.

### 3.3.2.1 Estimação dual de estados e parâmetros

Diversas aplicações de engenharia justificam o estudo do referido problema para estimação de estados e parâmetros. O desenvolvimento e análise de sensores virtuais para o processo de extração *offshore* consiste em uma dessas aplicações. Entretanto, é difícil encontrar modelos para tal sistema que expliquem o comportamento do mesmo em diferentes pontos de operação e que considere o efeito de envelhecimento dos poços, esses fatores implicam em mudanças no comportamento dinâmico do sistema. Considerando esse contexto no qual somente dados históricos de operação do processo estão disponíveis para obtenção de modelos, é razoável optar pela obtenção de modelos de estrutura mais simples (por exemplo, linear) e considerar a possibilidade de ajustar os parâmetros desses modelos ao longo do tempo. Neste caso, considera-se um problema de estimação dual de estados e parâmetros.

Dessa forma, considere que o sistema de interesse para identificação é representado por um modelo em espaço de estados linear (3.12)-(3.13), para o qual desejam-se estimar seus estados  $x_k$  e algum parâmetro  $\hat{\theta}_j$  de modo que esse modelo seja atualizado. Por manipulação matemática torna-se possível transcrever modelos em espaço de estados  $f$  e  $h$  para uma representação polinomial linear (1.3), e vice-versa, como apresentado na Subseção 3.3.1. Essa representação polinomial pode ser reescrita como

$$z_k = \sum_{i=1}^{n_\theta} \phi_{i,k} \hat{\theta}_i, \quad (3.22)$$

em que  $\phi_{i,k}$  faz referência ao  $i$ -ésimo regressor do modelo, para o qual tem-se  $n_\theta$  termos, e  $\hat{\theta}_i$  é o  $i$ -ésimo parâmetro do modelo, os quais são determinados a princípio de modo *offline* durante o processo de identificação do sistema.

Para o caso em que  $z_k$  corresponde à variável de estado estimada  $\hat{x}_k$  e considerando que se pretende estimar um único parâmetro, por meio de manipulação da equação (3.22) de modo a isolar o(s) parâmetro(s) de interesse, a seguinte representação é obtida

$$\hat{x}_k - \sum_{i=1, i \neq j}^{n_\theta} \phi_{i,k} \hat{\theta}_i = \phi_{j,k} \hat{\theta}_j. \quad (3.23)$$

Apesar de (3.23) referir-se à estimação de apenas um parâmetro  $\hat{\theta}_j$ , vale esclarecer que a extensão para estimação de dois ou mais é desenvolvida de forma similar.

Dessa maneira, o parâmetro  $\hat{\theta}_j$  é estimado em tempo de execução, e conforme discutido na Subseção 1.4.1, com esse novo parâmetro é realizada a atualização do modelo de processo  $f$ . Um diagrama representativo é mostrado na Figura 3.4, na qual por meio do FK é realizada a estimação dos estados  $\hat{x}_k$  que neste trabalho refere-se à pressão de fundo de poço PT1, e em seguida atualiza-se o modelo de processo desse filtro pela estimação *online* dos parâmetros  $\hat{\theta}_k$  com base no método dual.

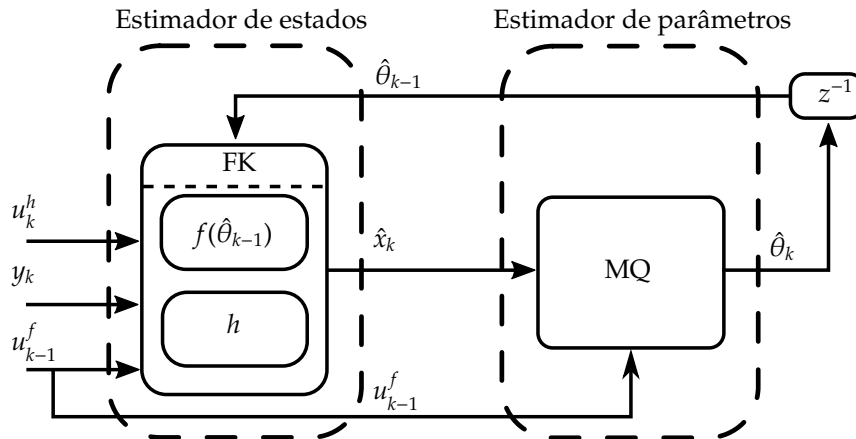


Figura 3.4: Diagrama geral para a estimação dual de estados e parâmetros. O FK utiliza de  $u_{k-1}^f$ ,  $u_k^h$ ,  $y_k$ , e  $\hat{x}_{k-1}$  para estimar  $\hat{x}_k$ . A entrada de processo  $u_{k-1}^f$  e estados estimados pelo filtro são enviados para o algoritmo de MQ que estima os parâmetros  $\hat{\theta}_k$  para atualização do modelo de processo  $f$  para ser utilizado no instante seguinte.

Como pode ser notado na Figura 3.4, a estratégia dual trata a estimação de estados e parâmetros de maneira independente, sendo essa realizada em dois passos. No primeiro referente ao estimador de estados, é desenvolvida a estimação dos estados  $\hat{x}_k$  por meio do FK no tempo  $k$ . No segundo passo referente ao estimador de parâmetros, por meio desses estados estimados  $\hat{x}_k$  e do vetor das variáveis de entrada do modelo de processo  $u_{k-1}^f$ , um estimador distinto é usado para atualizar parâmetros do modelo de processo do FK no tempo  $k$  para uso no instante  $k + 1$ .

Essa forma de tratar a estimação de estados e parâmetros de maneira desacoplada, oferece uma vantagem importante quando comparado com o método de estimação conjunta, na qual ambos estados e parâmetros são estimados de maneira simultânea pelo filtro. Pode-se projetar cada um dos estimadores separadamente, de modo a atenderem requisitos desejáveis tanto em relação a estimação de estados quanto dos parâmetros, além da possibilidade de desativar a atualização de parâmetro caso necessário.

Em (Proença, 2015; Teixeira et al., 2016), são obtidos resultados preliminares para o problema de análise de sensores virtuais para estimação da PT1, usa-se do método de estimação dual para atribuir maior robustez às estimativas. Para tal um esquema que emprega um FK para estimação de estados seguido de um algoritmo de mínimos quadrados recursivo (MQR) com fator de esquecimento (FE) constante para estimação de parâmetros é usado; conforme Figura 3.4. Esse algoritmo recursivo corresponde a uma modificação do MQRC que é mostrado na Subseção 3.2.1 para identificação de sistemas na etapa de estimação de parâmetros invariantes, e será apresentado com maiores detalhes a seguir. Apesar de o algoritmo MQR ser mais adequado para estimação de parâmetros variantes, como é o caso referente ao processo de extração de petróleo *offshore*, o fato de não haver sempre persistência de excitação nos dados compromete o desempenho dos modelos continuamente atualizados. Com isso, tal algoritmo pode

apresentar problemas de convergência na estimação dos parâmetros.

De modo a contornar esse problema, estudos sobre métodos para atualização de modelos em tempo de execução são realizados considerando a falta de persistência em dados, possibilitando assim a determinação de abordagens metodológicas para esse contexto. Em princípio, é dado foco ao estudo de métodos de estimação com ponderação variável, uma formulação geral para esse tipo de algoritmo é apresentada à frente. Esses algoritmos tendem a estimar os parâmetros do modelo de forma automática com base em algum critério que prioriza os dados contendo transientes. Em uma segunda instância, o foco passa a ser atribuído ao estudo de técnicas para detecção de transientes em dados. Dessa maneira, pode-se determinar se a janela de dados em análise é ou não adequada para estimar parâmetros, caso afirmativo, por meio do MQ em batelada descrito pela equação (3.5), realiza-se a atualização dos modelos.

### 3.3.2.1.1 Algoritmos recursivos com ponderação variável

O algoritmo MQRC apresentado na Subseção 3.2.1 na etapa de estimação de parâmetros é mais adequado quando o sistema não varia no tempo, de modo que faz sentido atribuir o mesmo peso às observações de diferentes instantes de tempo. Já para o caso de parâmetros variantes, modificações desse algoritmo podem ser propostas. Essas modificações se resumem em propor métodos de adaptativamente ponderar cada nova observação do processo (Aguirre, 2015).

Dentre os algoritmos modificados, tem-se o MQR com FE constante, o qual possui maior capacidade de adaptação à variação de parâmetros. Porém, esse pode passar por problemas de estouro da matriz de covariância, que ocorre quando se tem um sinal de entrada sem persistência de excitação (Lotufo, 2010).

O algoritmo MQR equivale ao MQRC quando o FE for igual a 1, ou seja, todos os dados passados e atuais usados para estimação dos parâmetros do modelo possuem a mesma influência, atribuindo o mesmo peso às observações usadas para se obter a estimativa atual dos mesmos. Neste trabalho, no contexto de algoritmos recursivos, é adotado o uso de algoritmos com ponderação variável dos dados, ou seja, o MQRC não é utilizado a princípio.

Considerando que o objetivo seja identificar um sistema a parâmetros variantes, de modo a ajustar esses para o modelo dinâmico, definimos a classe de algoritmos MQR com FE variável, cuja formulação geral é dada por

$$K_k = g^k \frac{P_{k-1} \psi_k}{\psi_k^T P_{k-1} \psi_k + \lambda_k}, \quad (3.24)$$

$$\hat{\theta}_k = \hat{\theta}_{k-1} + K_k [y_k - \psi_k^T \hat{\theta}_k], \quad (3.25)$$

$$P_k = \frac{1}{\lambda_k} \left( P_{k-1} - \frac{P_{k-1} \psi_k \psi_k^T P_{k-1}}{\psi_k^T P_{k-1} \psi_k + \lambda_k} \right), \quad (3.26)$$

sendo  $0 \ll \lambda_k < 1$  o FE,  $0 \leq g_k \leq 1$  é o tamanho do passo de correção (TPC),  $K_k$  é o ganho de Kalman e  $P_k$  é a matriz de covariância. Para o algoritmo MQR,  $\lambda_k$  é constante e o  $g_k=1$ ,  $\forall k$ .

Na literatura, muitos trabalhos têm sido desenvolvidos de modo a propor diferentes metodologias para se atualizar modelos preditivos, tendo como base a descrição geral apresentada pelas equações (3.24)-(3.26), em que comumente se varia o FE ou o TPC.

Em ambos os casos a ideia principal consiste em variar tal parâmetro, FE ou TPC, com base na riqueza dinâmica que os dados possuem. Na Figura 3.5 é mostrado um cenário em que tem-se o sinal de entrada  $u$  projetado para testes em um sistema de interesse, Figura 3.5(a), que corresponde a um cenário com excitação intermitente. Na Figura 3.5(b)-(c) é apresentado o modo de funcionamento de um algoritmo que trabalha com a variação do FE e do TPC por iteração, respectivamente.

Para o caso em que se pretende variar o FE, Figura 3.5(b), normalmente mantém-se  $g_k=1$  e com base em alguma metodologia proposta é feita a avaliação dos dados disponibilizados para ajustar o modelo. Para o cenário em que os dados recentemente disponibilizados são considerados relevantes para estimação, cenário referente ao primeiro e último intervalo da Figura 3.5(a), esses algoritmos tendem a atribuir um baixo valor ao FE. Caso contrário, o FE é mantido em seu valor máximo, de modo a considerar que os dados disponibilizados possuem a mesma relevância para estimação dos parâmetros, Figura 3.5(b). Quando se pretende trabalhar com a variação do TPC, Figura 3.5(c), o FE é mantido constante com um valor próximo ou igual a 1. Da mesma forma que o FE, por meio de algum algoritmo de ponderação também é realizada a avaliação dos dados disponibilizados para estimação dos parâmetros do modelo, porém, o TPC consiste em uma forma de restringir o ganho aplicado na atualização dos parâmetros. Assim, quando os dados são considerados adequados para estimação o TPC recebe um valor próximo de 1 e, caso contrário, será atribuído um valor próximo de zero, conforme apresentado na Figura 3.5(c).




Figura 3.5: Ilustração do modo de funcionamento de alguns algoritmos com ponderação variável em dados com excitação intermitente.

### 3.3.2.1.2 Análise para detecção de transientes em dados

Ao contrário dos algoritmos com ponderação variável, os quais estimam os parâmetros a medida que os dados são disponibilizados, a análise de detecção de transiente tem como objetivo avaliar em tempo de execução cada janela móvel de dados. Assim, determina-se o tamanho dessas janelas e conforme os dados são coletados avalia-se cada janela de modo a estabelecer se a mesma deve ser utilizada.

No estudo de sistema dinâmicos, tem-se que os transientes correspondem às respostas do sistema a mudanças em seus parâmetros e/ou devido às variações das suas entradas. Essas mudanças modificam o ponto de operação do sistema. Quando se deseja identificar esse tipo de sistema a partir de dados históricos, a detecção de transientes torna-se essencial.

A ideia por trás desse tipo de análise consiste em determinar se os dados coletados possuem informação dinâmica relevante. De certa forma, a detecção de transientes relaciona-se a presença de persistência de excitação nos dados.

# Estimação Adaptativa em Dados com Excitação Intermitente

---

## 4.1 Introdução

Neste capítulo são apresentados os resultados alcançados com o uso de algoritmos para estimação *online* de parâmetros a partir de dados com excitação intermitente. A descrição das técnicas e etapas metodológicas utilizadas são apresentadas, de modo a abordar os dois problemas de estimação propostos.

O primeiro problema refere-se à estimação de parâmetros variantes no tempo. Nesse contexto é realizada a comparação entre algoritmos de mínimos quadrados com ponderação variável. Para tal, investigam-se cenários para os quais a persistência de excitação muda com o tempo. Como meio de avaliar esses algoritmos, são utilizados dados simulados e experimentais. Para os testes simulados, é usado um sistema massa mola amortecedor, para o qual se deseja estimar a constante elástica da mola, que é variante no tempo. Como exemplo experimental, tem-se o problema de obter modelos preditivos para estimação da pressão de fundo para processos de extração de petróleo.

O segundo é um problema de estimação dual de estados e parâmetros. Duas abordagens para a etapa de estimação de parâmetros são tratadas. A primeira abordagem é recursiva e usa algoritmos de mínimos quadrados com ponderação variável, assunto tratado no primeiro problema proposto. Esses algoritmos tem por objetivo priorizar automaticamente os dados contendo transientes que favoreçam à estimação dos parâmetros. Vale lembrar que o fato de não se ter persistência de excitação nos dados compromete o desempenho dos modelos recursivamente atualizados. Esses algoritmos podem passar por problemas de estouro da matriz de covariância, levando à sua divergência, quando se tem um sinal de entrada sem persistência de excitação (Lotufo, 2010). Tais problemas motivam o estudo da segunda abordagem. Nessa abordagem, usam-se algoritmos em batelada para janelas de dados móveis nas quais transientes são detectados. As janelas são avaliadas em tempo de execução a fim de avaliar se a mesma possui informação dinâmica relevante para estimação. Nesse passo, ambas abordagens são testadas para atualização de modelos que compõem os sensores virtuais para estimação da pressão de fundo PT1 em processos *offshore*.

O restante do capítulo é organizado como descrito a seguir. Na Seção 4.2 são apresentadas as metodologias utilizadas nos dois problemas tratados, tanto em relação aos

estimadores recursivos para atualização de modelos preditivos; quanto a descrição das abordagens para estimação de parâmetros no contexto do método dual aplicado a sensores virtuais. Na Seção 4.3, têm-se os resultados obtidos para ambos os estudos realizados, e na Seção 4.4 são feitas as considerações finais sobre as tarefas desenvolvidas nesse capítulo.

## 4.2 Metodologia

### 4.2.1 Estimadores Recursivos de Parâmetros

Os algoritmos recursivos escolhidos para estudo neste trabalho podem ser classificados em três grupos de acordo com a sua forma de ponderar os dados. Assim têm-se: (i) FE constante, (ii) FE variante, e (iii) TPC. O primeiro refere-se ao método clássico, o qual é descrito em (Aguirre, 2015), e designado aqui como MQR. Para o grupo (ii), têm-se os algoritmos propostos por Beza e Bongiorno (2014), Paleologu et al. (2008) e Bhotto e Antoniou (2013), os quais são designados respectivamente como, FEV (FE variável), FEV1 e FEV2. O terceiro é descrito em (Vega et al., 2009), e designado como TPC. A principal ideia abordada por esses algoritmos concentra-se na melhoria da capacidade de rastreabilidade de transientes e redução da variação do erro em estado estacionário.

#### 4.2.1.1 Algoritmo fator de esquecimento variável

Segundo Beza e Bongiorno (2014), o algoritmo fator de esquecimento variável (FEV) proposto por eles apresenta uma variação controlada do FE, a qual proporciona uma rápida resposta a transientes por parte do algoritmo sem comprometer seu desempenho em estado estacionário. Sua motivação está no fato de que, para valores pequenos do FE, uma rápida convergência de estimação é obtida, mas sua capacidade de rejeição a ruídos presente nos dados é reduzida. Para valores altos do FE, o contrário é verificado. Assim, a ideia proposta consiste em atribuir pequenos valores para o FE quando ocorrem transientes, e esse valor é incrementado até atingir seu valor de máximo quando o sinal de saída estimado encontra-se em estado estacionário.

Os valores de máximo  $\lambda_{ss}$  e mínimo  $\lambda_{tr}$  do FE são determinados *a priori*. Um transiente pode estar relacionado a uma repentina mudança na entrada ou a alguma alteração no comportamento dinâmico do sistema. Para tal, calcula-se o erro *a priori* resultante,  $e_k = z_k - \psi_k \hat{\theta}_{k-1}$ . Caso esse erro seja superior a um limiar pré-definido  $d_{th}$ , o FE recebe o valor mínimo e retorna gradativamente para o máximo seguindo uma exponencial amortecida.

A forma de atualização do FE é dada por

$$\lambda_k = \begin{cases} \lambda_{tr}, & \text{se } |e_k| > d_{th} \\ \lambda_{ss} - (\lambda_{ss} - \lambda_{tr})e^{-k/\tau_{hp}}, & \text{caso contrário.} \end{cases} \quad (4.1)$$

Nos testes simulados da Subseção 4.3.1 os parâmetros adotados foram  $\lambda_{ss} = 0,99$ ,  $\lambda_{tr} = 0,95$ ,  $d_{th} = 0,41$  e  $\tau_{hp} = 4$  que é a constante de tempo de transição entre os FE projetados.

#### 4.2.1.2 Algoritmo fator de esquecimento variável 1

De acordo com Paleologu et al. (2008), a motivação por trás do algoritmo fator de esquecimento variável 1 (FEV1) por eles proposto está no fato de sistemas reais comumente terem o sinal de saída corrompido por um sinal de ruído aditivo. Com isso, o que se deseja é que a variância do erro *a priori* em estado estacionário seja igual à variância do ruído de medida.

O controle de atualização do FE baseia-se na estimativa do desvio padrão do ruído, que está relacionado com o desvio padrão do sinal de erro após convergência para a solução verdadeira. O método de atualização do FE é dado por

$$\lambda_k = \begin{cases} \lambda_{\max}, & \text{se } \hat{\sigma}_{e,k} \leq \gamma \hat{\sigma}_{v,k} \\ \min\left(\frac{\hat{\sigma}_{q,k} \hat{\sigma}_{v,k}}{\epsilon + |\hat{\sigma}_{e,k} - \hat{\sigma}_{v,k}|}, \lambda_{\max}\right), & \text{caso contrário.} \end{cases} \quad (4.2)$$

A equação (4.2) possui dois modos condicionais de operação. Caso a condição  $\hat{\sigma}_{e,k} \leq \gamma \hat{\sigma}_{v,k}$  seja atendida, o FE é mantido constante com o seu valor de máximo  $\lambda_{\max}$ . Caso contrário, o método de ponderação variável é usado. O parâmetro de configuração  $\gamma$  pode ser definido como  $1 < \gamma \leq 2$ . Para o caso em que o FE é atualizado a cada iteração, têm-se as estimativas dos desvios padrão do erro *a priori*  $\hat{\sigma}_{e,k}$ , do ruído  $\hat{\sigma}_{v,k}$ , e do produto  $q_k = \psi_k^T P_k \psi_k$ ,  $\hat{\sigma}_{q,k}$ , e  $\epsilon$  corresponde a um valor positivo e pequeno, de modo a garantir que não ocorra divisão por zero. Esses desvios padrão são obtidos a partir da sua estimativa de potência, sendo essas definidas na prática como

$$\hat{\sigma}_{e,k}^2 = \alpha \hat{\sigma}_{e,k-1}^2 + (1 - \alpha) e_k^2,$$

$$\hat{\sigma}_{q,k}^2 = \alpha \hat{\sigma}_{q,k-1}^2 + (1 - \alpha) q_k^2,$$

$$\hat{\sigma}_{v,k}^2 = \beta \hat{\sigma}_{v,k-1}^2 + (1 - \beta) v_k^2,$$

em que os parâmetros  $\alpha$  e  $\beta$  correspondem ao fator de memória entre as estimativas no tempo, com  $\alpha < \beta$ .

De modo a obter uma melhor compreensão sobre o algoritmo proposto, algumas considerações podem ser realizadas. Primeiramente, tem-se que quando atendida a parte condicional  $\hat{\sigma}_{e,k} \leq \gamma \hat{\sigma}_{v,k}$  do algoritmo, ou seja, quando o erro está dentro dos limites esperados, a velocidade de adaptação deve ser mínima  $\lambda_k = \lambda_{\max}$ .

Para o caso em que a condição  $\hat{\sigma}_{e,k} \leq \gamma \hat{\sigma}_{v,k}$  não seja atendida, resultando em um erro maior do que o esperado, recorre-se a uma maior velocidade de adaptação, que é obtida por meio do método de ajuste do FE apresentado em (4.2). O método de ponderação consiste em analisar, de certa forma, a persistência de excitação presente nos dados pela

estimativa do desvio padrão  $\hat{\sigma}_{q,k}$ , e considera-se a ocorrência de mudanças no sistema que sejam detectadas pela estimativa do erro *a priori*  $\hat{\sigma}_{e,k}$  e do ruído  $\hat{\sigma}_{v,k}$ . Por exemplo, quando ocorre uma mudança abrupta no sistema,  $\hat{\sigma}_{e,k} \gg \hat{\sigma}_{v,k}$ , se tem um valor pequeno para o FE (4.2), o que implica em uma rápida convergência e uma boa capacidade de rastreamento. À medida que quando o sistema converge para o estado estacionário  $\hat{\sigma}_{e,k} \approx \hat{\sigma}_{v,k}$  e o FE é mantido no seu valor máximo, resultando em uma redução da variação do erro em estado estacionário e uma menor velocidade de adaptação.

Nos testes simulados da Subseção 4.3.1 os principais parâmetros são escolhidos como,  $\alpha = 0,76$ ,  $\beta = 0,8$  e  $\gamma = 1,07$  e  $\lambda_{\max} = 0,99$ .

#### 4.2.1.3 Algoritmo fator de esquecimento variável 2

Segundo (Bhotto e Antoniou, 2013), a motivação para o algoritmo fator de esquecimento variável 2 (FEV2) está implicitamente ligada à possibilidade de subtrair o sinal de ruído do sinal de erro, caso as propriedades do ruído presente nos dados sejam conhecidas. Assim, com o sinal livre de ruído tem-se o algoritmo de atualização proposto por eles. Seu método de atualização proposto, é obtido pela minimização da média quadrática do sinal de erro *a posteriori* sem ruído.

Para esse método de atualização, não é necessário pré-especificar um FE, sendo esse determinado exclusivamente pelo algoritmo. A solução encontrada para esse problema necessita do cálculo da estimativa do erro *a priori* sem ruído, dado por

$$\hat{e}_{f,k} = \text{sgn}(e_k) \max(|e_k| - t, 0),$$

em que  $t = \sqrt{c_1 \sigma_v^2}$  é um parâmetro limitante, com  $c_1$  sendo uma constante a ser escolhida e  $\sigma_v^2$  a variância do ruído presente nos dados conhecida *a priori*, e  $e_k$  é o erro *a priori* propriamente dito. A função  $\text{sgn}(e_k)$  é usada para determinar o sinal da estimativa.

Pelo uso da estimativa do erro *a priori* sem ruído, estima-se seu desvio padrão como

$$\sigma_k = \beta \sigma_{k-1} + (1 - \beta) \hat{e}_{f,k}^2,$$

a partir do qual, tem-se a seguinte formulação para determinação do FE, representada como

$$\lambda_k = 1 - \frac{2\sigma_k}{M(\sigma_k + c_1 \sigma_v^2)}, \quad (4.3)$$

em que se determinou  $c_1$  sendo um inteiro com valores na faixa entre 50 e 110 (nesse trabalho),  $M = n_\theta$ , e  $\sigma_v^2$  a variância do ruído nos dados. Dessa maneira, pode ser observado que, pelo cálculo do desvio padrão  $\sigma_k$ , esperam-se valores com  $\sigma_k \gg \sigma_v^2$  durante a presença de transientes nos dados dinâmicos resultando em  $\lambda_k \approx 1 - 2/M$ , e sendo  $\sigma_k \approx 0$  durante o estado estacionário, tem-se  $\lambda_k \approx 1$ .

Os parâmetros associados a esse algoritmo para os testes simulados apresentados na Subseção 4.3.1 foram especificados como  $M = 3$ ,  $c_1 = 110$ ,  $\beta = 0,9$ ,  $\sigma_v^2 = 5,76 \times 10^{-4}$ .

#### 4.2.1.4 Algoritmo tamanho do passo de correção

Segundo Vega et al. (2009), a motivação para proposta do algoritmo tamanho do passo de correção (TPC) é relacionada à ocorrência de ruídos impulsivos, mudanças bruscas, ocasionadas em um determinado instante persistirem por algum tempo, afetando consideravelmente a estimativa resultante. O fato do sinal de ruído que ocorre em um tempo  $k$  persistir por tempos consecutivos, está no fato do valor atribuído ao FE para o caso em que considera-se o MQR com FE constante ter um valor próximo de 1. Com isso, os dados disponibilizados até o tempo  $k$ , que estão contaminados por ruído impulsivo, terá influência desse ruído por algum tempo, pelo fato do algoritmo está considerando dados passados como relevantes para estimação.

De modo a propor um método robusto a ruídos impulsivos, a ideia está em limitar o quanto esse ruído pode influenciar na atualização dos parâmetros por parte do algoritmo. Para atender essa limitação, uma restrição em relação à variação de parâmetros entre dois instantes subsequentes de estimação é adicionada na função de custo usada no projeto do algoritmo de atualização.

Assim, o método resultante proposto funciona por meio do chaveamento automático entre as ponderações de atualização impostas pelo MQR e frações dessa. A atualização dos parâmetros é dada por

$$\hat{\theta}_k = \hat{\theta}_{k-1} + \min\left(\sqrt{\delta_{k-1}}, \|\Delta\hat{\theta}_k^{RLS}\|\right) \frac{\Delta\hat{\theta}_k^{RLS}}{\|\Delta\hat{\theta}_k^{RLS}\|}, \quad (4.4)$$

em que  $\Delta\hat{\theta}_k^{RLS} = K_k e_k$ , sendo  $K_k$  o ganho de Kalman, e  $e_k$  o erro *a priori*. O  $\delta_k$  é o parâmetro que restringe a atualização do algoritmo no máximo até o seu valor, que é estimado por  $\delta_k = \alpha\delta_{k-1} + (1 - \alpha) \min(\delta_{k-1}, \|K_k\|^2 e_k^2)$ , onde  $0 < \alpha < 1$  é um fator de memória. Com o tempo,  $\delta_k$  tende a um valor estacionário, diminuindo a capacidade de rastreamento, assim, tem-se a determinação de um método de controle para ambientes não estacionários, que determina quando  $\delta_k$  necessitará ser reinicializado.

O método de controle para reinicialização usado aqui, passa por alguns passos de definições. Primeiramente, tem-se a definição de duas variáveis positivas e inteiras, designadas como  $V_T$  e  $V_D < V_T$ , em que  $V_T$  é relacionada com a quantidade de parâmetros  $M = n_\theta$ . Assim, a primeira condição do método de controle para iniciar a pesquisa para determinar se deve ser reinicializado o  $\delta_k$  é definida como

$$\text{se } \text{mod}(k, V_T) = 0, \quad \text{ctrl}_{new} = \frac{c^T D c}{V_T - V_D}, \quad (4.5)$$

em que a função  $\text{mod}(a, b)$  é referente ao resto da divisão entre os números inteiros  $a$  e  $b$ ,  $D = \text{diag}(1, \dots, 1, 0, \dots, 0)$  refere-se à matriz diagonal para a qual os primeiros  $V_T - V_D$  termos tem valores iguais a um,  $c^T = \mathcal{O}(|e_k|/(\epsilon + \|\psi_k\|), \dots, |e_{k-V_T+1}|/(\epsilon + \|\psi_{k-V_T+1}\|))$ , sendo  $\mathcal{O}(\cdot)$  um operador de ordenação crescente,  $\psi_k$  o vetor de regressores de entrada e  $\epsilon$  um

valor pequeno e positivo para evitar divisão por zero. Também tem-se que  $ctrl_{old}$  refere-se ao valor do estimador durante as  $V_T$  amostras anteriores e algum limitante  $\zeta$ , assim os próximos passos a serem realizados à cada  $V_T$  iterações do algoritmo são:

---

**Algoritmo 1:** CONTROLE DO  $\delta_k$  PARA AMBIENTES NÃO ESTACIONÁRIOS

---

```

1 início
2    $\Delta_k = (ctrl_{new} - ctrl_{old})/\delta_{k-1}$ ;
3   se  $\Delta_k > \zeta$  então
4     |  $\delta_k = \delta_o$ ;
5   senão se  $ctrl_{new} > ctrl_{old}$  então
6     |  $\delta_k = \delta_{k-1} + (ctrl_{new} - ctrl_{old})$ ;
7   senão
8     |  $\delta_k = \alpha\delta_{k-1} + (1 - \alpha) \min(\delta_{k-1}, \|K_k\|^2 e_k^2)$ ;
9   fim
10   $ctrl_{old} = ctrl_{new}$ ;
11 fim

```

---

Segundo [Vega et al. \(2008\)](#), quando altos valores são atribuídos para  $V_T$ , tem-se pequenos valores de  $\delta_k$  em estado estacionário, porém ocasiona um aumento de complexidade computacional e gera um atraso na capacidade de rastreabilidade de transientes. A diferença entre  $V_T - V_D$  tem relação com o nível de ruído presente nos dados, quanto maior esse nível maior deve ser a diferença entre essas variáveis, de modo a descartar uma larga quantidade de amostras ruidosas que gerariam discrepâncias para a estimação de mudanças no sistema. O parâmetro limitante  $\zeta$  é usado para detectar a maior mudança no sistema que não pode ser seguida por um pequeno valor  $\delta_{k-1}$ , e assim é realizada a reinicialização da sequência de deltas, de modo a rastrear tal mudança rapidamente. Se ocorre uma mudança, mas essa não é grande o bastante, a segunda condição apresentada no algoritmo (linha 5), pode resolver o problema de rastreamento modificando a sequência de deltas de forma mais suave. Caso não se detecte mudança no sistema a sequência de deltas é atualizada normalmente para o caso de sistemas estacionários, conforme apresentado ao início da discussão aqui desenvolvida, algoritmo TPC, ou na linha 8 (algoritmo 1).

Nos testes simulados da Subseção 4.3.1 as principais variáveis desse algoritmo são escolhidas como,  $\lambda = 0,99$ ,  $\alpha = 0,65$ ,  $M = 3$ ,  $V_T = 1M$ ,  $V_D = 0,5V_T$ ,  $\zeta = 40$  e  $\delta_o = 0,67$ .

## 4.2.2 Métodos para Estimação Dual de Estados e Parâmetros

Para o estudo do problema de estimação dual de estados e parâmetros, duas abordagens para atualização dos parâmetros  $\hat{\theta}_k$  são tratadas nesta Subseção. A primeira abordagem é baseada em algoritmos de mínimos quadrados recursivos, como apresentado na Figura 4.1(a). A segunda emprega um estimador de parâmetros em batelada para a etapa de estimação de parâmetros, conforme mostrado na Figura 4.1(b). Para

tal, realiza-se uma detecção de transientes em uma janela de dados móvel, de modo a determinar se essa será ou não usada para atualização dos parâmetros.

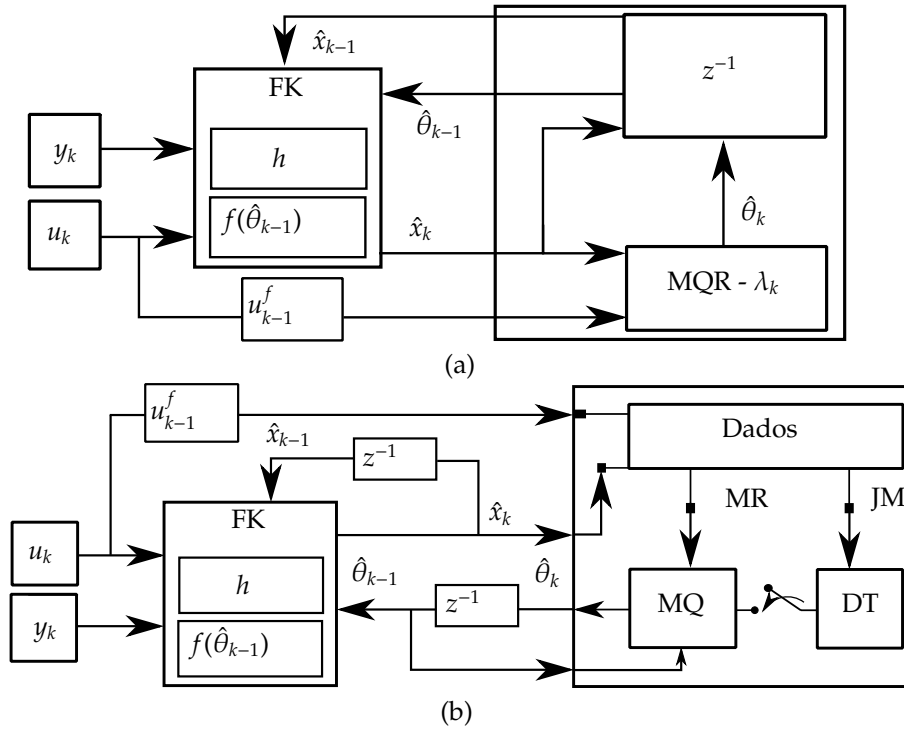


Figura 4.1: (a) Abordagem 1 para estimação recursiva de parâmetros. Primeiramente tem-se que o FK é atualizado com as estimativas de parâmetros  $\hat{\theta}_{k-1}$  do instante anterior. Em seguida, o FK utiliza  $u_k = [u_{k-1}^f \ u_k^h]^T$ ,  $y_k$  e  $\hat{x}_{k-1}$  para estimar  $\hat{x}_k$ . Esses são enviados para o algoritmo MQR- $\lambda_k$ , o qual estima os parâmetros  $\hat{\theta}_k$  para atualização do modelo de processo  $f$  para ser utilizado no instante seguinte.

(b) Abordagem 2 para estimação em batelada de parâmetros. Em cada intervalo de busca, estuda-se a janela móvel de dados (JM) armazenada no *buffer* Dados. Caso essa atenda aos requisitos de detecção de transientes (DT), a estimação dos parâmetros para atualização do modelo de processo do filtro em estudo é realizada.

#### 4.2.2.1 Abordagem com estimador recursivo de parâmetros

Nesta abordagem, são utilizados algoritmos recursivos com ponderação variável, para os quais será considerado o caso em que a ponderação consiste no ajuste do FE a cada iteração  $k$ . Na Figura 4.1(a), é apresentado um diagrama esquemático dessa abordagem. Primeiramente, tem-se que a entrada  $u_k$  e a medida de observação  $y_k$  são aplicadas ao FK, o qual estima os estados  $\hat{x}_k$  do sistema no instante  $k$ . Para tal, os estados  $\hat{x}_{k-1}$  e parâmetros  $\hat{\theta}_{k-1}$  estimados no instante  $k-1$  também são usados. De forma desacoplada, o filtro interage com o algoritmo de mínimos quadrados recursivos com ponderação variável, MQR- $\lambda_k$ , de modo a atualizar seu modelo de processo  $f$  pela

estimação de seus parâmetros  $\hat{\theta}_k$ . Assim, o filtro é atualizado para uso na próxima iteração  $k + 1$ .

O algoritmo recursivo escolhido para uso é descrito em [Beza e Bongiorno \(2014\)](#), e apresentado na Subseção 4.2.1 na qual é designado como FEV. Esse algoritmo trata do uso de um FE variável como método de ponderação dos dados.

As configurações atribuídas para esse algoritmo nesse novo contexto correspondem às seguintes variáveis:  $\lambda_{ss} = 0,9999$ ,  $\lambda_{tr} = 0,95$ ,  $d_{th} = 0,073$  e  $\tau_{hp} = 4$ .

Para fins de comparação, também é considerado o algoritmo com FE constante, descrito em [Aguirre \(2015\)](#) e designado aqui como MQR com FE constante ajustado para  $\lambda=0,9999$ . Esse é um caso especial do FEV, quando não se detecta mudança repentina na entrada, em que  $\lambda_k$  é constante para todo  $k$ .

#### 4.2.2.2 Abordagem com estimador em batelada com detecção de transientes

Na segunda abordagem, é utilizado o algoritmo de mínimos quadrados em batelada (MQ) para estimação de parâmetros considerando janelas móveis de dados (JM). A motivação para esse método está na não-garantia de haver persistência de excitação nos dados coletados. Em processos industriais, por exemplo, tal condição configura operação normal do processo. Assim, é usada uma técnica para detecção de transientes na janela de dados, determinando se a mesma é apropriada ou não para identificação, de modo a habilitar ou descartar essa para uso na estimação dos parâmetros.

A Figura 4.1(b) mostra o diagrama representativo dessa abordagem. Para o filtro em estudo, tem-se que a cada iteração  $k$  se estimam os estados  $\hat{x}_k$  usando para tal os sinais de entrada  $u_k$ , da observação  $y_k$  e dos estados estimados a uma amostra de instante anterior  $\hat{x}_{k-1}$ . Durante as iterações do algoritmo, o campo determinado como Dados armazena os sinais da entrada do modelo de processo  $u_{k-1}^f$  e dos estados estimados  $\hat{x}_k$ . Esses compõem a matriz de regressores (MR). Quando esse conjunto de dados alcança um tamanho especificado como adequado para análise, faz-se a detecção de transiente (DT). Isso se repete entre intervalos especificados para pesquisa nas novas JM. Para cada uma que atenda aos requisitos de excitação pré-determinados, é habilitada a estimação por meio do MQ, e a matriz de regressores é usada para estimação. Esse estudo das janelas de dados é realizado em tempo de execução. Assim, à medida que uma janela é classificada como detentora de informação dinâmica significativa, que corresponde ao caso em que transientes são detectados nos dados, a atualização de parâmetros do modelo de processo  $f$  é realizada usando dados de tal janela. Para a estimação dos parâmetros, podem ser consideradas duas alternativas de algoritmos em batelada. A primeira, refere-se ao algoritmo de MQ convencional (3.5) apresentado na etapa (iv) de estimação de parâmetros, na Subseção 3.2.1 de identificação de sistemas. A segunda alternativa é o algoritmo MQ com regulação, o qual mantém certa influência dos parâmetros pré-definidos em estimativas anteriores sobre as novas estimativas, de modo que os valores não divirjam muito dos obtidos anteriormente. Sua formulação é

dada como

$$\hat{\theta} = [\Psi^T \Psi + P_0^{-1}]^{-1} [\Psi^T Z + P_0^{-1} \theta_0],$$

em que  $\Psi \in \mathbb{R}^{N \times n_\theta}$  é a MR,  $\theta_0$  é a última estimativa obtida para os parâmetros,  $P_0$  é a matriz de covariância dessa estimativa, e  $Z$  é o vetor de  $N$  medições da saída. Para cálculo da incerteza nos parâmetros tem-se,  $P_0 \approx (\Psi^T \Psi)^{-1} \hat{\sigma}_v^2$ , em que  $\hat{\sigma}_v^2 = \xi^T \xi / (N - n_\theta)$ , com o vetor de resíduos  $\xi = Z - \psi \hat{\theta}$  (Aguirre, 2015). Vale lembrar que para o cálculo de  $P_0$  o  $\Psi$  utilizado refere-se à matriz da iteração anterior. Esse algoritmo equivale ao MQ convencional quando,  $\theta_0 = 0$  e  $P_0^{-1} = 0$ .

#### 4.2.2.2.1 Técnica de detecção de transientes

A técnica de detecção de transientes (DT) usada neste trabalho é baseada no método *offline* proposto por Ribeiro e Aguirre (2015). A proposta desenvolvida por eles, tem como objetivo realizar a classificação das janelas de dados sob uma massa de dados específica. Assim, tendo como foco trabalhar com detecção de janelas *online*, foi realizada a adaptação desse método, de modo que janelas pudessem ser avaliadas em tempo de execução.

A ideia base para essa técnica possui dois passos, conforme apresentado na Figura 4.2. O primeiro trata da análise de persistência de excitação na JM, enquanto o segundo passo verifica se há correlação desses dados com as entradas do modelo.




Figura 4.2: Diagrama simplificado da técnica de detecção de transientes. Este diagrama detalha o bloco DT mostrado na Figura 4.1(b).

No primeiro passo, avalia-se a persistência de excitação nos dados por meio de regressões do sinal de interesse  $\hat{x}_k$  (saída da equação (3.12)) que refere-se neste trabalho à pressão do fundo de poço PT1 a ser estimada. Isso é feito pelo ajuste de um modelo auto-regressivo (AR) para tal sinal. A partir desse modelo, se pretende propor meios de inferir a quantidade de informação contida nesse sinal, e quanto maior for a quantidade de informação capaz de se capturar desse sinal, melhores estimativas para os parâmetros do modelo serão obtidas.

Considere o modelo linear AR

$$\hat{x}_k = a_1 \hat{x}_{k-1} + a_2 \hat{x}_{k-2} + \dots + a_n \hat{x}_{k-n},$$

em que  $\{a_1, a_2, \dots, a_n\}$  são parâmetros a serem estimados. Se o sinal  $\hat{x}_k$ , que corresponde ao estado de interesse para estimação neste trabalho, é conhecido no intervalo  $k=1, \dots, N$ ,

em que  $N$  se refere ao tamanho da JM, reescrevendo na forma matricial, tem-se  $A\hat{b} = \hat{x}$ , sendo

$$A = \begin{bmatrix} \hat{x}_0 & \hat{x}_{-1} & \dots & \hat{x}_{-n+1} \\ \hat{x}_1 & \hat{x}_0 & \dots & \hat{x}_{-n+2} \\ \vdots & \vdots & \ddots & \vdots \\ \hat{x}_{N-1} & \hat{x}_{N-2} & \dots & \hat{x}_{N-n} \end{bmatrix}, \quad \hat{x} = \begin{bmatrix} \hat{x}_1 \\ \hat{x}_2 \\ \vdots \\ \hat{x}_N \end{bmatrix}, \quad \hat{b} = \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_n \end{bmatrix},$$

em que  $A \in \mathbb{R}^{N \times n}$  é a matriz de regressão,  $\hat{b} \in \mathbb{R}^n$  é o vetor de parâmetros e  $\hat{x} \in \mathbb{R}^N$  é o vetor da JM.

Dessa maneira, ao procurar solucionar essa equação matricial, tem-se o ponto chave para o estudo da persistência nos dados, uma vez que o posto da matriz  $A$  corresponde ao limite máximo de parâmetros  $\hat{b}$  que se consegue estimar com essa JM. Por sua vez, o posto está relacionado com a quantidade de informação contida no sinal e com isso, tornando-se uma boa forma para avaliar se essa JM é adequada para identificação.

Ribeiro e Aguirre (2015) propõem uma redefinição do conceito de posto para obter uma estimativa robusta ao ruído, dada por

$$r_2^{ef} = \sum_{i=2}^n H[(\sigma_{i-1} - \sigma_i) - l_2],$$

em que  $H$  refere-se a função de Heaviside, que retorna 1 se o argumento em estudo não é negativo e 0 se é negativo,  $\sigma$  refere-se ao vetor de valores singulares da matriz de regressão  $A$ . O posto estimado é baseado na diferença de valores singulares próximos  $(\sigma_i - \sigma_{i-1})$ , que é comparada por um valor limitante  $l_2 = 0,1$ , valor definido para o presente trabalho em questão. Assim, se a diferença for maior que esse limite, considera-se que os valores singulares em análise são distintos. Caso a estimativa  $r_2^{ef}$  atenda às especificações pré-determinadas, o segundo passo é realizado.

O segundo passo tem como finalidade avaliar o índice de correlação (IC)  $s$  entre a janela de dados e cada uma das  $p$  entradas do modelo. O IC apresentado é uma medida baseada na FCC (3.2), porém, tem como resultado um escalar que corresponde à correlação entre os sinais analisados. Assim, como tem-se apenas um escalar como meio de avaliação da correlação geral entre os sinais, é possível automatizar essa análise. Sua formulação é dada por

$$s = \sum_{\tau=-\tau_{\max}}^{\tau_{\max}} g(\rho(\tau), \tau, l),$$

em que  $\tau_{\max}$  é o máximo atraso de interesse e  $g(\rho(\tau), \tau, l)$  é definido como:

$$g(\rho(\tau), \tau, l) = \begin{cases} 0, & \text{se } |\rho(\tau)| \leq l, \\ \frac{|\rho(\tau)| - l}{|\tau|}, & \text{se } |\rho(\tau)| > l \text{ e } \tau \neq 0, \\ |\rho(\tau)| - l, & \text{se } |\rho(\tau)| > l \text{ e } \tau = 0, \end{cases}$$

em que  $\rho(\tau)$  é a função de correlação cruzada normalizada e  $l = \frac{1,96}{\sqrt{N}}$  é o intervalo de confiança de 95%, sendo  $N$  o tamanho da janela em amostras.

As JM que atenderem ambas as propriedades são usadas para a estimação dos parâmetros do modelo pelo algoritmo de mínimos quadrados em batelada MQ.

O algoritmo em batelada usado para estudo nessa abordagem é designado como DT-MQ. Para os testes experimentais realizados na Subseção 4.3.2 os seguintes parâmetros foram utilizados:  $r_2^{ef} \geq 9$ ,  $s_1 > 1$  e  $s_2 > 0,5$ . Os limiares designados como  $s_1$  e  $s_2$  correspondem à correlação entre a variável de interesse e cada uma das entradas do modelo a ser atualizado. Neste trabalho, têm-se que a variável de interesse a ser estimada é a pressão de fundo de poço (PT1), e como entradas do modelo de processo (3.10) que compõe o FK a ser atualizado, a vazão de *gas lift* (FT4) e temperatura montante no choke de produção (TT3), respectivamente. O tamanho da JM é de 2000 amostras e o intervalo de pesquisa entre janelas de 500 amostras.

## 4.3 Resultados

Nesta Seção são apresentados os resultados obtidos para ambos os problemas propostos na Seção 4.1, por meio das metodologias e configurações descritas ao longo da Seção 4.2.

### 4.3.1 Análise dos Estimadores Recursivos de Parâmetros

Nesta Subseção o objetivo concentra-se em avaliar o desempenho dos algoritmos recursivos para o problema de estimação de parâmetros variantes em modelos preditivos. São usados dois sistemas testes, um simulado e um experimental tratados a seguir.

#### 4.3.1.1 Resultados simulados

A seguir são apresentados os resultados obtidos pelos métodos de estimação aplicados a um sistema massa mola amortecedor, em que se pretende estimar a constante elástica da mola  $\kappa$  que é variante. Sua representação discretizada em espaço de estados, com período de amostragem  $T_s = 0,1$ , é dada por:

$$\begin{bmatrix} x_{1,k} \\ x_{2,k} \end{bmatrix} = \begin{bmatrix} 1 & T_s \\ \frac{-\kappa T_s}{m} & 1 - \frac{c T_s}{m} \end{bmatrix} \begin{bmatrix} x_{1,k-1} \\ x_{2,k-1} \end{bmatrix} + \begin{bmatrix} 0 \\ \frac{T_s}{m} \end{bmatrix} u_k, \quad (4.6)$$

$$y_k = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} x_{1,k-1} \\ x_{2,k-1} \end{bmatrix} + v_k, \quad (4.7)$$

em que assume-se que  $x_{1,k}$  é a posição e  $x_{2,k}$  é a velocidade, ambos medidos no sistema,  $m$  refere-se à massa,  $c$  é o fator de amortecimento e  $\kappa$  corresponde à constante elástica da mola. A entrada  $u_k$  é a força externa aplicada ao sistema. Por fim,  $y_k$  é a saída do sistema corrompida por um ruído de medição  $v_k$ .

Considerando a equação (4.6), para estimação da constante elástica pode-se isolar a expressão de  $x_{2,k}$ , e reescrever no formato de regressão linear,  $z_k = \psi_k^T \hat{\theta}$ , em que:

$$\begin{aligned} z_k &= y_k, \\ \psi_k &= [y_{1,k} \ y_{2,k} \ u_k]^T, \\ \hat{\theta} &= [\hat{\theta}_1 \ \hat{\theta}_2 \ \hat{\theta}_3]^T. \end{aligned}$$

Com isso, têm-se que,  $\hat{\theta}_3 = \frac{T_s}{m}$ ,  $\hat{\theta}_2 = \frac{1-cT_s}{m}$  e  $\hat{\theta}_1 = -\frac{\kappa T_s}{m}$ , de forma que a constante elástica pode ser estimada como  $\hat{\kappa} = -\hat{\theta}_1/\hat{\theta}_3$ .

Para implementação, é adicionado um ruído branco gaussiano  $v$  no modelo de saída (4.7), com variância  $\sigma_v^2$ , que resulta numa relação sinal/ruído (SNR) de 20dB. Os valores usados para simulação são,  $m = 1$ ,  $c = 5$ ,  $x_1(0) = 0,1$ ,  $x_2(0) = 0,01$  e  $\sigma_v^2 = 6 \times 10^{-4}$ .

A partir desse momento, em que foram determinadas as configurações que o sistema deve possuir e suas características dinâmicas de interesse para análise dos estimadores, é necessário projetar o sinal de testes dinâmicos adequados para esse contexto proposto.

Dessa maneira, serão consideradas as situações em que o sinal de entrada possui ou não persistência de excitação e o parâmetro do sistema varia ou permanece constante. Na Figura 4.3, são ilustrados os cenários de interesse, para ambos será considerado o caso em que o sinal de entrada  $u$  inicia excitante e transita por um intervalo de tempo para um sinal sem excitação, em seguida retorna a condição inicial e o teste é finalizado. O cenário 1 corresponde ao caso que o parâmetro é variante, enquanto o mesmo é constante no cenário 2. Como sinal persistentemente excitante, optou-se pelo PRBS, o qual foi projetado conforme parametrização descrita em (Aguirre, 2015), de modo que esse sinal contenha características desejadas para se obter sucesso na identificação.

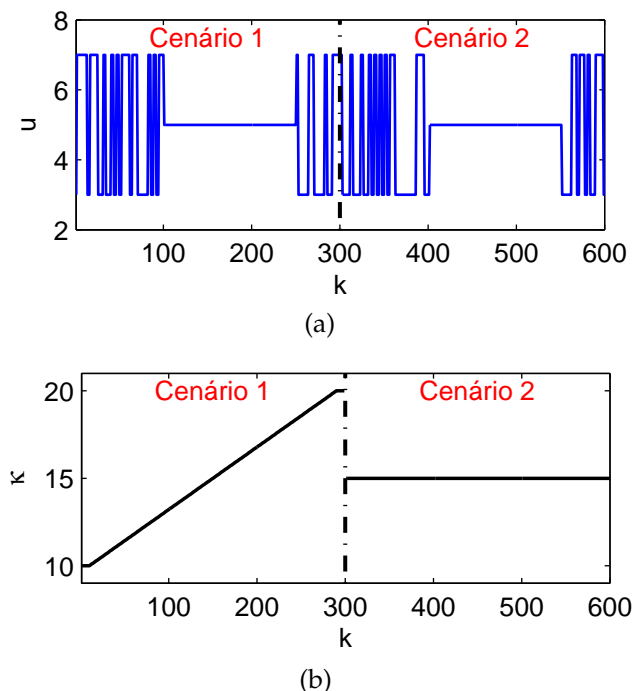


Figura 4.3: Ilustração do comportamento dinâmico dos sinais para teste em uma escala reduzida de 10:1 das iterações da simulação real realizada. (a) Sinal de entrada e (b) Variação da contante elástica  $\kappa$ . Ambos sinais foram divididos em dois cenários para teste, numerados como 1 e 2.

#### 4.3.1.1.1 Estudo do cenário 1

As estimativas resultantes para esse cenário estão apresentadas na Figura 4.4. Como pode ser notado, os algoritmos produziram boas estimativas para os intervalos que o sinal de entrada é persistentemente excitante. Para o intervalo em que essa excitação cessa (de 1000 a 2500), tais algoritmos tornaram-se menos eficientes, resultando em uma perda de precisão na estimação da constante elástica  $\kappa$  que tem seu valor variante. Esse é o cenário que caracteriza um caso crítico para estimação, devido o parâmetro permanecer variando no tempo e os dados não possuem informação dinâmica relevante. Para os resultados obtidos, têm-se que os algoritmos FEV2 e TPC produziram as piores estimativas para o cenário crítico. O ideal nessa situação seria que cada algoritmo mantivesse o valor de FE máximo, com  $\lambda=1$ , de modo a atribuir o mesmo peso aos dados recentes e passados, ou TPC mínimo, com  $g_k=0$ , tal que os parâmetros não fossem atualizados. A principal diferença entre os algoritmos estudados, além do método usado para determinar o valor do fator de ponderação, conforme apresentado na Subseção 4.2.1, está na possibilidade de o usuário pré-especificar ou não os limites de máximo e/ou mínimo desse fator.




Figura 4.4: Estimativas da constante elástica para o cenário de teste 1. (a) algoritmos FEV1, MQR e FEV, e (b) algoritmos FEV2 e TPC. As linhas verticais (---) indicam o instante em que ocorre a transição entre o sinal de entrada com e sem excitação.

No algoritmo FEV1 não é possível delimitar o menor valor que o FE pode atingir. Assim, pode haver situações em que o valor atribuído a esse parâmetro, Figura 4.5(a), seja pequeno  $\lambda_k \approx 0$ . Para esse caso, tem-se um descarte significativo do conhecimento dinâmico obtido sobre o sistema por meio dos dados anteriormente usados na estimação, e é atribuído nesse momento maior peso aos dados recentemente disponibilizados. Com isso, caso o algoritmo determine um FE pequeno para um intervalo em que não se tenha excitação nos dados, uma pobre estimativa é obtida.

Para o algoritmo FEV os valores de mínimo e máximo do FE são especificados pelo usuário, assim como a delimitação do maior erro de predição e tempo para transição entre esses valores do FE, conforme Subseção 4.2.1 na descrição desse algoritmo. A configuração desses parâmetros é realizada, a princípio, de modo *offline* pela análise de dados dinâmicos do sistema, de modo que o algoritmo seja eficiente. Para o sistema massa mola estudado, o algoritmo produziu ponderações adequadas para o caso em que a entrada era constante, mantendo o FE com valor de máximo Figura 4.5(b).

O algoritmo FEV2 faz o controle de atualização do FE sem a necessidade de especificar seus delimitantes. Porém, pelo método de atualização resultante para esse algoritmo (4.3) e pelo ajuste dos parâmetros de configuração do mesmo, tem-se uma variação do FE em valores próximos do máximo. Para o cenário aqui estudado, durante o intervalo sem excitação, esse algoritmo manteve o FE máximo  $\lambda = 1$ , conforme

desejado, Figura 4.5(c).

Para o algoritmo TPC, tem-se que o FE é constante e, para tratar a variação a ser aplicada nos parâmetros do modelo identificado, pondera-se o tamanho do passo de correção  $g_k$ . Pela configuração desse algoritmo, é desejável inibir que atualizações no modelo sejam realizadas quando os dados não possuem relevância dinâmica. Porém, averiguou-se que em instantes em que o sinal é excitante, também ocorre certa atenuação nas correções, Figura 4.5(d). Assim, pobres estimativas são obtidas quando não há excitação nos dados, devido ter-se abstraído pouca informação relevante durante os intervalos com excitação.

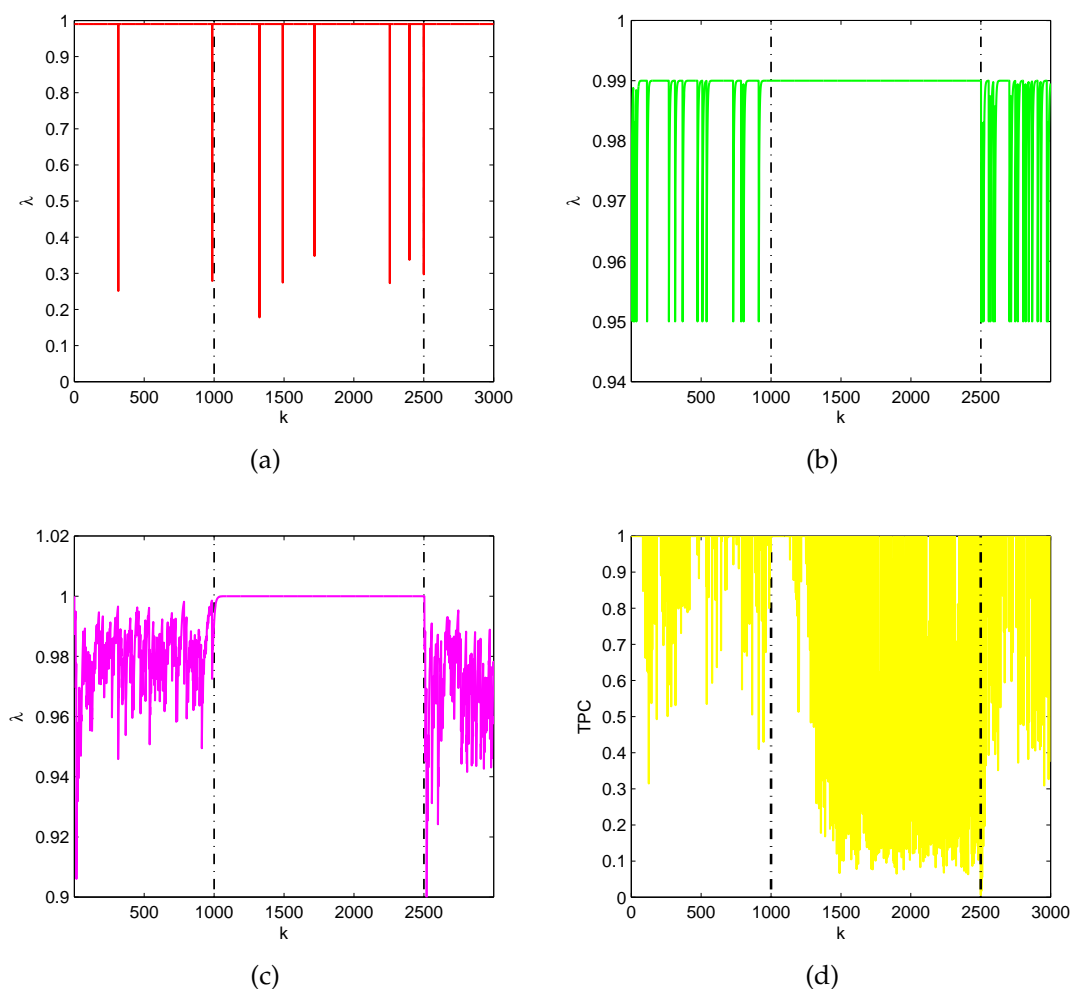


Figura 4.5: Evolução temporal do FE e do TPC para o cenário de teste 1. Algoritmos: (a) FEV1, (b) FEV, (c) FEV2 e (d) TPC. As linhas verticais (---) indicam o instante em que ocorre a transição entre o sinal de entrada com e sem excitação.

Na Figura 4.5 é apresentada a evolução temporal do fator de ponderação para cada um dos algoritmos estudados. Nota-se que a atuação dos algoritmos foi aproximada-

mente pertinente com o que se esperava, apesar de o algoritmo FEV1 e TPC realizarem algumas ponderações “indevidas”. Essas, referem-se ao caso em que têm-se algumas atualizações para o FE durante o intervalo em que a entrada não possuía excitação, Figura 4.5(a). E ao caso em que o algoritmo TPC pondera o passo de correção durante o intervalo em que a entrada era persistentemente excitante, Figura 4.5(d).

#### 4.3.1.1.2 Estudo do cenário 2

Este cenário corresponde ao caso em que o parâmetro  $\kappa$  do sistema é constante durante toda a simulação. Dessa maneira, foi determinado  $\kappa = 15$  e o sinal de entrada possui as mesmas características do sinal usado no cenário 1 de teste. Na Figura 4.6 são mostradas as estimativas obtidas.




Figura 4.6: Estimativas da constante elástica para o cenário de teste 2. (a) algoritmos MQR, FEV e FEV1; (b) algoritmos FEV2 e TPC. As linhas verticais (---) indicam o instante em que ocorre a transição entre o sinal de entrada com e sem excitação.

Para esse novo cenário de teste, notou-se que os algoritmos foram mais eficientes na estimação de  $\kappa$  para o intervalo em que não há excitação nos dados quando comparado com o mesmo intervalo no cenário de teste 1. Entre os fatores que explicam esse ocorrido, está o fato de  $\kappa$  ser constante durante toda a simulação, o que de certo modo induz menos atualizações do modelo por parte dos algoritmos durante esse intervalo.

A Figura 4.7, mostra a evolução temporal do fator de ponderação dos algoritmos em análise para o cenário supracito. A princípio, os algoritmos que apresentaram um comportamento, de certa forma contraditório com o que se esperava em relação aos intervalos dinâmicos, foram o FEV1 e o TPC.

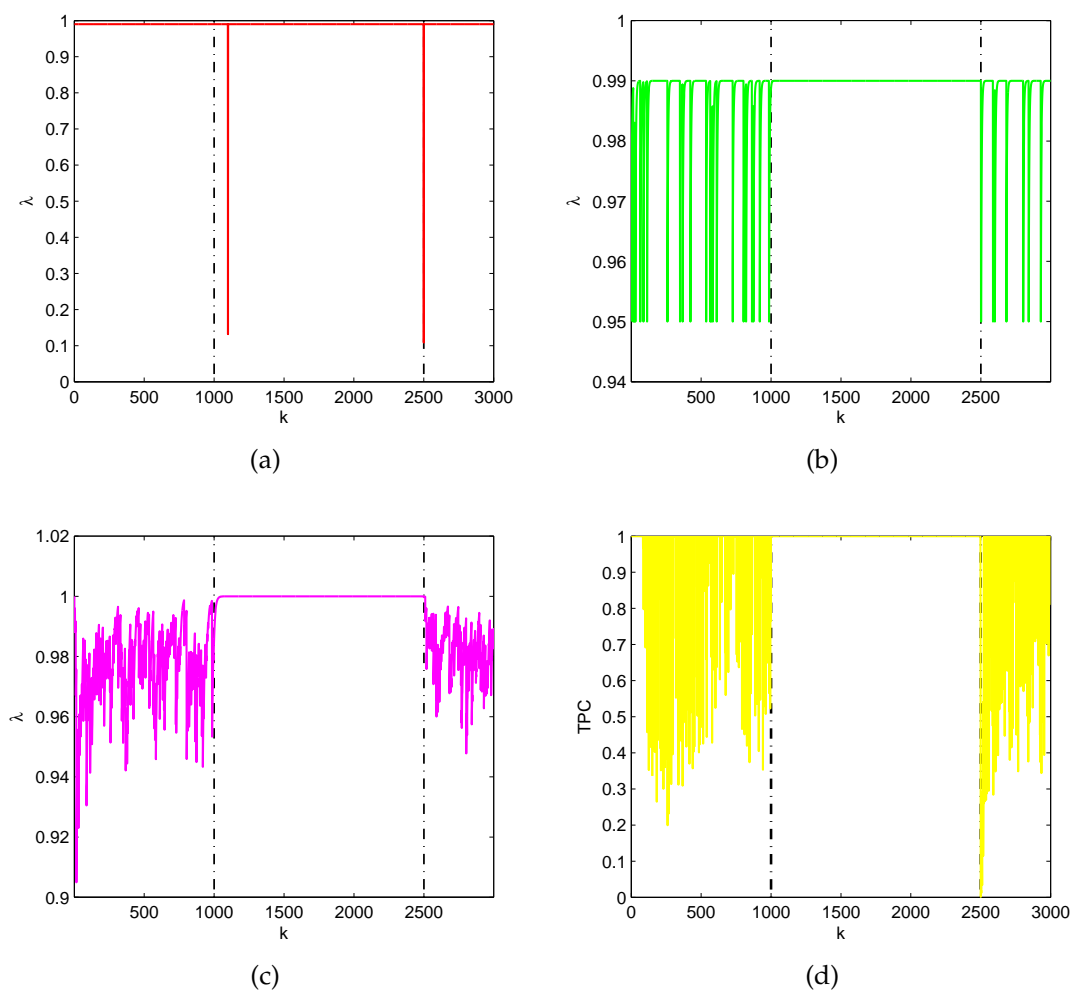


Figura 4.7: Evolução temporal do FE e do TPC para o cenário de teste 2. Algoritmos: (a) FEV1, (b) FEV, (c) FEV2 e (d) TPC. As linhas verticais (---) indicam o instante em que ocorre a transição entre o sinal de entrada com e sem excitação.

No algoritmo FEV1, têm-se que o fator de ponderação é atualizado apenas durante os intervalos em que não se tinha excitação nos dados, Figura 4.7(a), que se refere a um caso indesejado. Além disso, esse algoritmo está constantemente em atualização, com um FE máximo  $\lambda_{\max} = 0,99$ , o que de certo modo também contribui para uma pobre estimativa da variável  $\kappa$  para o presente cenário.

O TPC inibiu com maior ênfase as atualizações durante o intervalo em que havia excitação nos dados, e permitiu que o modelo fosse atualizado durante o intervalo que

a excitação foi cessada, Figura 4.7(d), o que também caracteriza uma forma inadequada de funcionamento do algoritmo.

#### 4.3.1.1.3 Avaliação das estimativas resultantes

Como meio de quantificar o desempenho que cada um dos algoritmos obteve para os cenários de teste propostos, será usado o método EPAM (3.9) para avaliação das estimativas, apresentado na Subseção 3.2.1 para a etapa (iv) de identificação de sistemas. A Tabela 4.1 apresenta os valores quantitativos de desempenho.

Tabela 4.1: Avaliação das estimativas pelo método EPAM, para o sistema massa mola amortecedor.

Algoritmos	Índice EPAM	
	Cenário 1	Cenário 2
MQR	7,92	1,57
FEV1	4,88	1,61
FEV	3,31	1,59
FEV2	6,06	1,46
TPC	7,19	1,44

Para o cenário 1, os algoritmos FEV e FEV1 foram os que produziram estimativas mais acuradas, enquanto o algoritmo MQR produziu o pior índice EPMA. Isso pode ser explicado, pelo fato de os algoritmos com FE variante extraírem maior conhecimento do comportamento dinâmico do sistema, que varia no tempo, durante o intervalo em que a entrada era excitante. Dessa maneira, para o período em que a entrada é constante, esses algoritmos sofrem menor degradação.

No cenário 2, nota-se que o desempenho de todos os algoritmos é muito parecido, como pode ser observado pelos valores de EPAM produzidos.

#### 4.3.1.2 Resultados experimentais poço R

Os resultados apresentados a seguir correspondem ao uso dos algoritmos com ponderação variável na estimação de parâmetros do modelo (3.10). Esse modelo foi desenvolvido por Proença (2015) para estimar a pressão de fundo (PT1) do poço R de dados da Petrobras. Assim, pretende-se manter a mesma estrutura do modelo e considerar que seus parâmetros são ajustáveis. Para validação do modelo resultante realizou-se simulação livre.

## 4.3.1.2.1 Estudo das estimativas

Na Figura 4.8, são apresentados os sinais de entrada e a saída medida, assim como algumas das estimativas resultantes de acordo com os algoritmos de atualização estudados e o caso em que se tem a simulação do modelo (3.10) com parâmetros constantes.

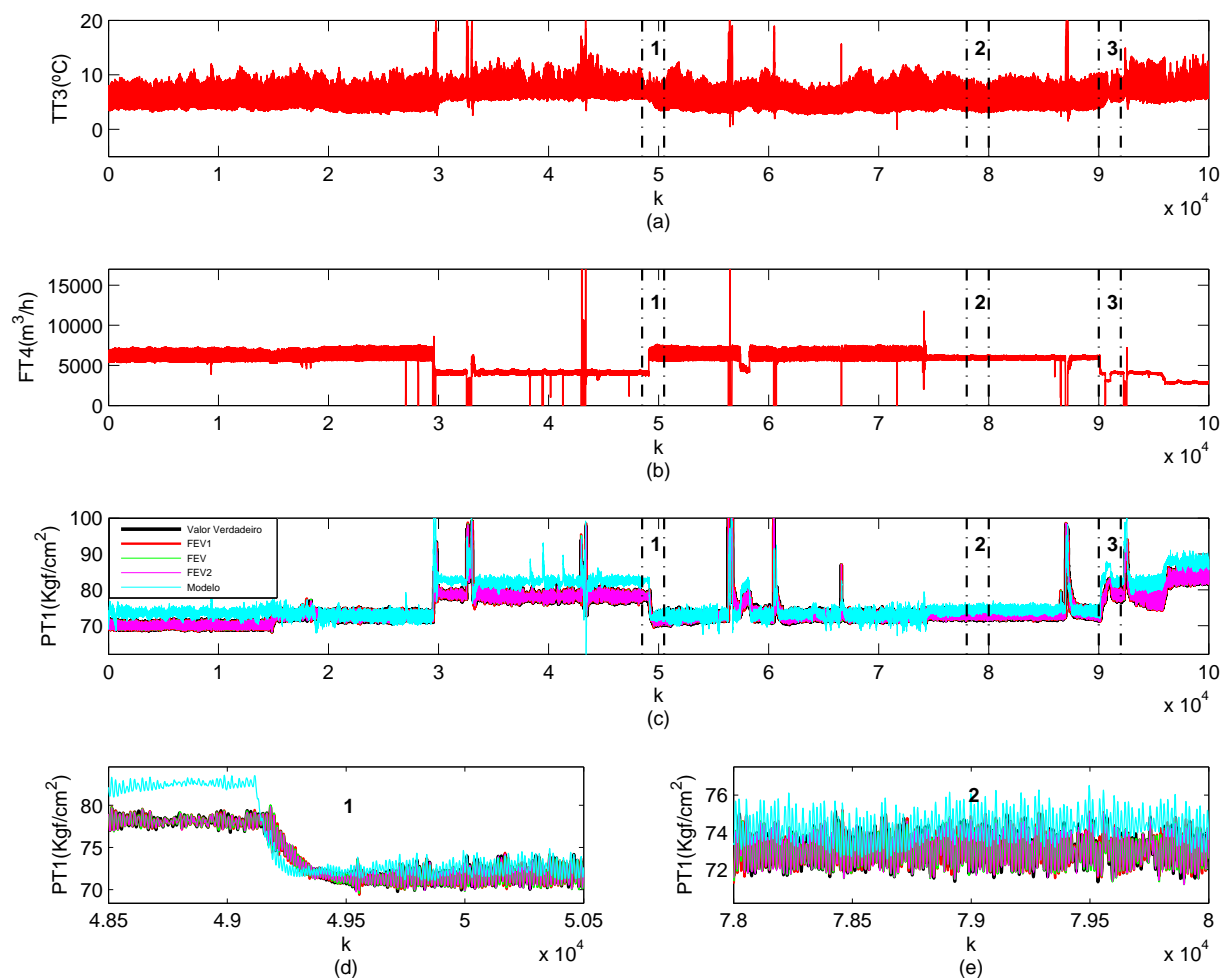


Figura 4.8: Estimativas da pressão de fundo de poço por meio de um modelo preditivo, considerando os algoritmos recursivos propostos para a etapa de atualização de parâmetros. Sinais de entrada (a) TT3 e (b) FT4; (c) algoritmos FEV1, FEV, FEV2; (d) primeira e (e) segunda janela de dados estimados. As linhas verticais (---) especificam as 3 janelas de dados selecionadas, consideradas da esquerda para a direita, cada uma com 2000 amostras. *Modelo* indica a simulação do modelo preditivo (3.10) com parâmetros constantes.

O algoritmo TPC não é mostrado porque o mesmo diverge com o tempo e o MQR devido os resultados obtidos com o uso dos outros algoritmos recursivos para atualização dos modelos apresentarem resultados muito parecidos. Para análise, escolheram-se 3 intervalos de estimação por meio da massa de dados apresentada na Figura 4.8, os

quais são delimitados pelas linhas verticais mostradas na mesma. O primeiro e terceiro intervalo referem-se a uma transição de patamar em que se percebe correlação dessa mudança devido às entradas. O segundo refere-se ao caso em que não se tem excitação persistente nas entradas.

#### 4.3.1.2.2 Avaliação das estimativas resultantes

Na Tabela 4.2 são mostrados os valores de índice EPAM obtidos para as estimativas resultantes. Para a estimação da PT1, se considerado a diferença apresentada nas casas decimais para os resultados obtidos com o uso dos algoritmos recursivos, têm-se que os algoritmos FEV2 e FEV foram os que produziram melhores resultados quando comparados com os demais. No entanto, as diferenças apresentadas são irrisórias, podendo considerar que os resultados alcançados são equivalentes. O algoritmo TPC não foi capaz de detectar a mudança de patamar em tempo hábil, deteriorando com isso sua estimativa, levando à sua divergência. Essa perda na capacidade de detecção do TPC pode ser explicada pelo fato desse algoritmo ter atenuado boa parte dos dados com informação dinâmica relevante para estimação, tornando-se incapaz de acompanhar tais mudanças. Obviamente a simulação do modelo com os parâmetros constantes produziu os piores resultados, sugerindo a vantagem de se usar métodos de atualização *online* de parâmetros.

Para o caso em que não há mudança de patamar nos dados, ou seja, as variáveis de entrada e saída de interesse permanecem em estado estacionário, janela 2 Figura 4.8(e), têm-se que os algoritmos recursivos produziram piores estimativas da PT1. A piora na capacidade de estimação dos modelos para o caso descrito era esperada, devido à janela 2 referir-se a um intervalo em que a persistência de excitação nos dados é baixa.

Tabela 4.2: Avaliação das estimativas pelo método EPAM, considerando o uso de um modelo preditivo para estimação da pressão de fundo no Poço R estudado.

Algoritmos	Índice EPAM - Poço R		
	Janela 1	Janela 2	Janela 3
MQR	0,31	0,32	0,25
FEV1	0,31	0,32	0,24
FEV	0,23	0,24	0,20
FEV2	0,20	0,21	0,20
Modelo	2,69	1,66	5,10

#### 4.3.2 Análise das Abordagens propostas para Estimação Dual

Para o caso em que é estudado o problema de estimação dual de estados e parâmetros, as abordagens de atualização propostas na Subseção 4.2.2 são aplicadas em modelos que compõem o FK, para estimação da PT1 conforme apresentado a seguir.

#### 4.3.2.1 Resultados experimentais poço R

O sistema experimental aqui tratado é o mesmo utilizado para testes na Subseção 4.3.1, em que é considerado para uso os dados do Poço R para estimação de sua PT1. No entanto, ao invés de se atualizar um modelo de predição, faz-se a atualização do modelo de processo  $f$  que compõe o FK que é responsável por estimar a PT1 para os estudos aqui realizados.

Como discutido anteriormente, os modelos matemáticos que compõem o FK em questão foram propostos por Proença (2015) e Teixeira et al. (2016). Tais modelos foram identificados na representação ARX polinomial, e referem-se ao modelo de processo  $f$  (3.10) e o modelo de observação  $h$  (3.11). Em seguida, esse par de modelos foi reescritos como (1.1)-(1.2), mais especificamente no formato (3.12)-(3.13) pelo fato dos modelos identificados serem lineares, e então foram usados no FK.

Em (Proença, 2015; Teixeira et al., 2016), observou-se a importância de atualizar os parâmetros de (3.10) ao longo do tempo enquanto a PT1 é estimada pelo FK.

#### 4.3.2.2 Estudo da abordagem recursiva e em batelada

Para os estudos aqui realizados foram determinados dois tipos de testes, um referente ao caso que atualiza-se apenas um parâmetro, e outro em que estima-se todos os parâmetros do modelo de processo  $f$ .

Inicialmente considera-se o caso em que se estima apenas um parâmetro do modelo de processo  $f$ , referente ao primeiro atraso da saída  $z_{k-1}$ , para o modelo (3.10). A escolha desse parâmetro a ser atualizado deve-se à grande importância desse regressor ao se explicar a saída  $z_k$ . Para o caso em que se utiliza da abordagem em batelada, o algoritmo a princípio usado é o MQ convencional (3.5). Na Figura 4.9, são apresentadas as estimativas resultantes e a evolução desse parâmetro nas janelas selecionadas para estudo.

Para uma melhor análise das estimativas resultantes, escolheram-se duas janelas de dados menores com 7000 amostras cada (aproximadamente 5 dias) numeradas como 1 e 2 e delimitadas pelas linhas verticais na Figura 4.9(a). A primeira refere-se a uma transição no ponto de operação, Figura 4.9(b), que corresponde ao caso em que os dados do processo possuem persistência de excitação. Já a segunda, é o cenário em que o sinal permanece num mesmo patamar, sem transiente, Figura 4.9(c), que representa a situação em que os dados utilizados são pobres para estimação. As variações resultantes do parâmetro referente ao regressor  $z_{k-1}$  em cada uma das janelas selecionadas são apresentadas nas Figuras 4.9(d)-(e), as quais sofrem alterações na casa decimal de  $10^{-4}$  e  $10^{-3}$ , respectivamente.

Para o primeiro cenário, Figura 4.9(b), é possível notar que o algoritmo DT-MQ teve resultados mais satisfatórios quando comparado com os demais, obtendo uma estimativa mais aproximada do valor verdadeiro. Isso pode ser explicado, pelo fato de a detecção de transientes ocasionar apenas mudanças pontuais no parâmetro do

modelo, Figura 4.9(d). Assim, a atualização é adequadamente aplicada conforme se tem informação relevante nos dados, por exemplo, na amostra de 96000, é perceptível a ocorrência de mudança no patamar. Considerando o intervalo a partir da amostra de 100000, Figura 4.9(d), em que transientes não são detectados, o parâmetro é mantido constante pelo algoritmo DT-MQ. Porém, permanece variando para os algoritmos recursivos, tornando-os mais propícios a gerar degradação do modelo, fazendo com que o DT-MQ se sobressaia.

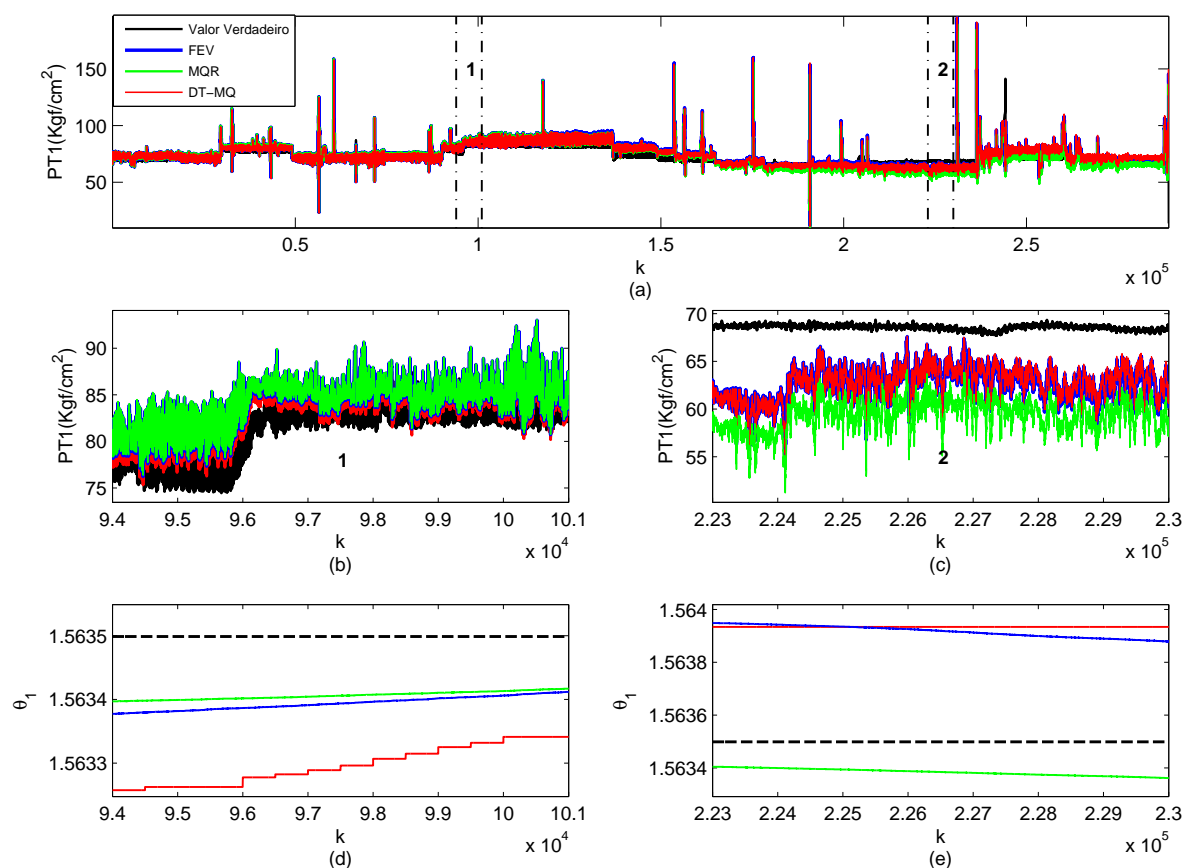


Figura 4.9: Estimativas da pressão de fundo  $PT_1$ , considerando cada um dos algoritmos usados nas abordagens propostas para a etapa de atualização de um parâmetro do modelo de processo  $f$  do FK no contexto de estimação dual. (a) algoritmos FEV, MQR e DT-MQ, estimando a massa de dados total referente à aproximadamente 7 meses; (b) janela de dados 1; (c) janela de dados 2; (d) e (e) evolução do parâmetro estimado para as janelas 1 e 2, respectivamente. As linhas verticais (---) indicam os intervalos selecionados para análise, cada um com 7000 amostras.

No segundo cenário, Figura 4.9(c), no qual não há transientes, o parâmetro mantém-se constante para o DT-MQ como esperado. Para o algoritmo FEV foram obtidos resultados muito próximos do DT-MQ, e mais satisfatórios que o MQR. Isso é possivelmente explicado, pelo fato de o algoritmo com FE variante extraírem maior conhecimento di-

nâmico do sistema durante os intervalos em que há excitação nos dados, quando comparado com o MQR. Com isso, para os casos em que os dados são pobres para estimação, os algoritmos que absorveram maior conhecimento *a priori* tendem a sofrer menor degradação em suas estimativas.

#### 4.3.2.3 Avaliação das estimativas resultantes

O índice para avaliação de desempenho dos métodos investigados é o EPAM. Os cenários considerados para avaliação são apresentados nas Figuras 4.9(b)-(c), referidos respectivamente como Janela 1 e 2. Para essas janelas, também foram desenvolvidas a análise em que se realiza a estimação de todos os parâmetros do modelo de processo  $f$ . Nesse caso, a fim de amenizar as variações nos parâmetros na abordagem em batelada, usa-se do algoritmo de MQ com regulação descrito na Subseção 4.2.2, o qual restringe as correções com base na incerteza estimada dos parâmetros anteriores.

Tabela 4.3: Avaliação pelo método EAPM das estimativas resultantes do FK para a pressão de fundo do poço R. Considerando os algoritmos de atualização usados nas abordagens propostas para o contexto de estimação dual.

Algoritmos	Índice EPAM			
	estimando um parâm.		estimando todos os parâm.	
	Janela 1	Janela 2	Janela 1	Janela 2
MQR	2,79	13,60	13,02	7,21
FEV	2,68	8,67	36,24	19,05
DT-MQ	1,87	8,51	2,17	9,24

Para o caso de se estimar um parâmetro, percebe-se que o algoritmo DT-MQ produziu os melhores resultados; veja Tabela 4.3. Quando pretende-se comparar o desempenho entre os métodos recursivos, o FEV produziu melhores resultados em relação ao MQR com FE constante. No caso em que se usa a janela 1 de dados, a pequena diferença entre o desempenho dos algoritmos recursivos está relacionada ao fato de os dados em análise serem persistentemente excitantes. Para a janela 2, o FEV também foi melhor que o MQR, já que em momentos anteriores o FEV foi capaz de capturar maiores conhecimentos sobre a dinâmica do sistema. Para esse último cenário, não havia transiente nos dados.

Para o caso em que se estimam todos os parâmetros, considerando que o DT-MQ para esse caso utiliza do algoritmo em batelada com regulação, seu desempenho permanece superior aos demais algoritmos quando considerada a janela 1 para análise. Já para a janela 2, em que não se tem persistência de excitação nos dados, o algoritmo MQR produziu melhores resultados. Essa melhora nos resultados por parte do algoritmo MQR quando comparado com o FEV consiste no fato de menores atualizações no modelo serem produzidas por esse algoritmo, à medida que todos os parâmetros

sejam atualizados. Como pode ser notado, esse maior grau de liberdade para se atualizar modelos pode ocasionar piora relevante por parte dos métodos de estimação com ponderação variável na presença de dados com baixa persistência de excitação. Para o algoritmo DT-MQ, devido à falta de transiente nos dados, os parâmetros são mantidos constantes, sendo isso mostrado em parte pela Figura 4.9(e). Assim, pode-se considerar que a última atualização do modelo, por esse algoritmo, não capturou de modo adequado a dinâmica implícita nos dados, sendo esse o motivo pelo qual melhores resultados não foram obtidos por esse algoritmo.

## 4.4 Conclusões do Capítulo

Este capítulo abordou os algoritmos recursivos e metodologias impostas para o procedimento de atualização de modelos preditivos em tempo de execução, para casos em que o cenário de teste considerado corresponde a dados com excitação intermitente. Em seguida, foram propostas duas abordagens para atualização de parâmetros tendo como base o método para estimação dual de estados e parâmetros, em que atualizou-se o modelo de processo que compõe o FK usado para estimar a pressão de fundo PT1. Uma das abordagens considera o uso de algoritmos recursivos, a outra utiliza de uma técnica para detecção de transientes em janelas móveis de dados. Para cada janela considerada apropriada para estimação segundo a técnica de detecção de transiente, a atualização do modelo de processo  $f$  do FK foi realizada em tempo de execução por um algoritmo em batelada. Ambas abordagens foram estabelecidas com o propósito de tornarem os sensores virtuais mais robustos às mudanças dinâmicas para casos em que os dados do processo de interesse possuem excitação intermitente. Os resultados obtidos foram então apresentados para uma avaliação tanto qualitativa quanto quantitativa em relação aos algoritmos usados e abordagens propostas. Por meio desses resultados algumas conclusões foram obtidas, tanto para o caso em que se analisou o desempenho de algoritmos recursivos para atualização de parâmetros em modelos preditivos, quanto das abordagens de atualização de modelos que compõem o FK. Para o primeiro caso, notou-se que os resultados sugerem a vantagem de se usar métodos de atualização recursiva desde que haja fator de ponderação variável para tratar excitação intermitente. No segundo caso, em que analisou-se o desempenho dos estimadores de parâmetros para abordagem dual, concluiu-se por exemplo, a vantagem de que estimar apenas um parâmetro do modelo é mais seguro para a abordagem recursiva. À medida que para a abordagem com detecção de transientes esse problema não ocorre.

# Sensor Virtual para Vazão de Óleo

---

## 5.1 Introdução

Neste capítulo é apresentado o estudo de viabilidade para o projeto de um sensor virtual para a estimação da vazão de óleo em processos de petróleo *offshore*. O foco a ser mantido, a princípio, refere-se à primeira etapa da técnica de identificação de sistemas, na qual são realizados estudos nos dados do processo de modo a averiguar se a obtenção de modelos preditivos é possível.

O restante desse capítulo é organizado em três seções, em que na Seção 5.2 é apresentada a metodologia aplicada para estudo de correlação nos dados do processo. Na Seção 5.3 são apresentados os resultados alcançados pelo uso da metodologia proposta, e para fechar o capítulo na Seção 5.4 são realizadas as considerações finais.

## 5.2 Metodologia para Análise dos Dados

Nesta seção são apresentados os procedimentos usados no intuito de se detectar a existência de correlação entre a vazão de óleo no separador de testes (FT5.1) e as demais variáveis do processo, as quais foram apresentadas na Tabela 2.1 e na Figura 2.4.

Os dados disponibilizados para análise referem-se a janelas com diferentes quantidade de amostras, as quais correspondem aos intervalos em que os poços de petróleo são alinhados para aferir sua vazão de óleo produzida; veja Figura 1.2. Esses intervalos para atribuir a medição de vazão a cada poço em sua determinada plataforma tem duração e ocorrência imprevistas por dependerem da atuação da ANP. Para os estudos aqui desenvolvidos utilizam-se dados coletados de três poços: E, M e P. Para esses dados tem-se o histograma da Figura 5.1 que relaciona a quantidade de janelas de dados, referentes ao período de Junho de 2014 a Agosto de 2015, com a duração em horas de coletas desenvolvidas nas mesmas.

Como pode ser notado na Figura 5.1, uma grande dispersão em relação ao tempo em que cada poço é mantido em alinhamento é encontrada, variando de 4 a 72 horas. Para essa massa de dados disponibilizada, têm-se 56 janelas de dados considerando os três poços nos instantes de alinhamento para teste.

Dentre essas janelas de dados, verificou-se a existência de diferentes cenários quanto ao comportamento dinâmico e estático. Por isso, pretende-se verificar se há, e qual tipo

de correlação é encontrada entre a saída FT5.1 e as demais variáveis do processo, as quais são as candidatas a entradas do modelo.




Figura 5.1: Histograma da duração em horas de cada janela no momento em que os poços E, P e M estão alinhados para testes. Para o período Junho de 2014 a Agosto de 2015, foram totalizadas 56 janelas de dados nesse conjunto de poços.

### 5.2.1 Análise do Comportamento Dinâmico

Primeiramente foi realizada a seleção dos intervalos de dados em que a vazão de óleo apresentava comportamento dinâmico. Como exemplo, consideremos algumas janelas referentes ao poço M.

Na Figura 5.2, são apresentadas duas formas de transição encontradas nas janelas de dados com comportamento dinâmico, as quais foram classificadas de forma visual como transições “abruptas” (Figura 5.2(a)) e “suaves” (Figura 5.2(b)).

A partir de janelas com essas características, é realizado o estudo de correlação cruzada, de modo que cada janela de alinhamento da vazão de óleo seja analisada separadamente com as demais variáveis do processo para o mesmo intervalo de tempo correspondente à coleta. Esse estudo, é ilustrado na Figura 5.3.

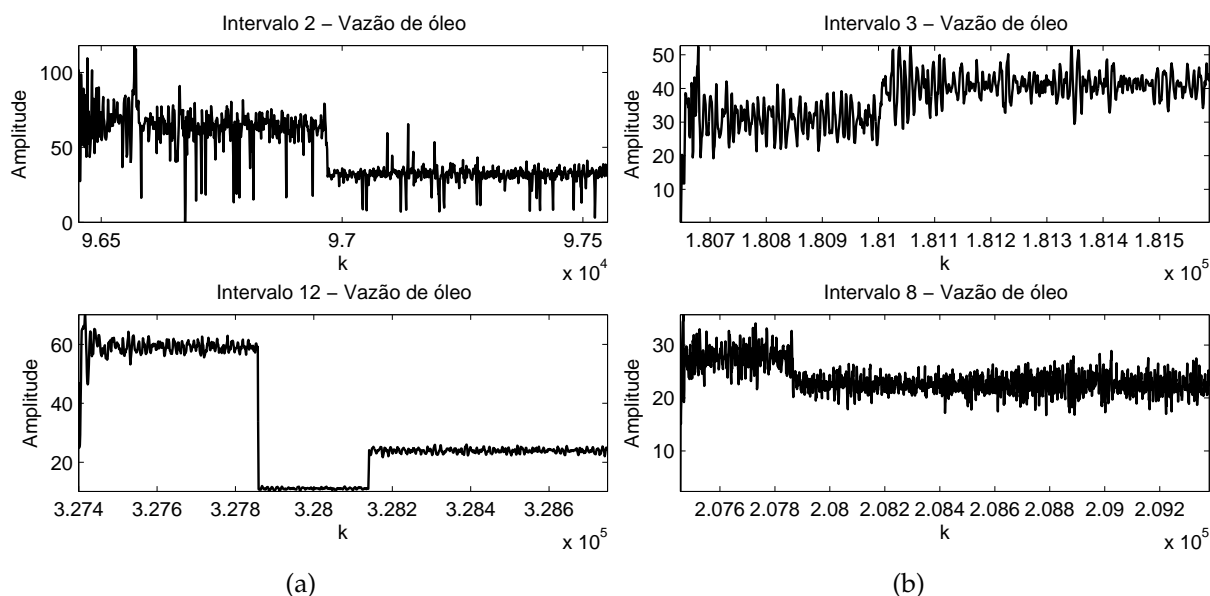


Figura 5.2: Algumas das janelas de dados com comportamento dinâmico referentes ao Poço M, quando o mesmo está alinhado para testes. Em (a), são apresentados dois intervalos de alinhamento com uma transição “abrupta”, enquanto que, em (b), tem-se uma transição “suave”.

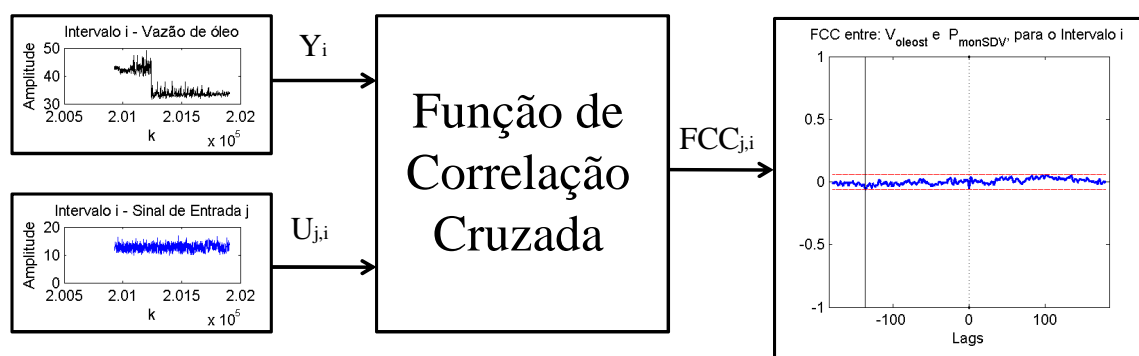


Figura 5.3: Diagrama representativo do estudo de correlação cruzada entre os intervalos de alinhamento da vazão de óleo com as demais variáveis candidatas a entrada. As linhas verticais são usadas como referências para análise, a pontilhada (· ·) indica o ponto em que não se tem atraso, a contínua (–) indica o ponto em que se tem maior pico de correlação para o intervalo de atrasos analisado. Já as horizontais pontilhadas (– –) demarcam a região do limite de confiança de 95%.

## 5.2.2 Análise do Comportamento Estático

Considerando que se deseja realizar a seleção das janelas de dados que apresentem comportamento estático, algumas janelas do poço M foram selecionadas. Tais janelas são mostradas na Figura 5.4.




Figura 5.4: Algumas das janelas de dados com comportamento estático referentes ao Poço M, quando o mesmo está alinhado para testes.

Quando se deseja fazer estudo de correlação estática entre essas janelas, torna-se necessário eliminar as amostras relacionadas a transientes do início da operação de alinhamento. Esse tipo de cenário pode ser notado nas primeiras amostras apresentadas na Figura 5.4. Assim, é essencial o descarte de uma certa quantidade de amostras para que esse estudo não resulte em respostas incoerentes.

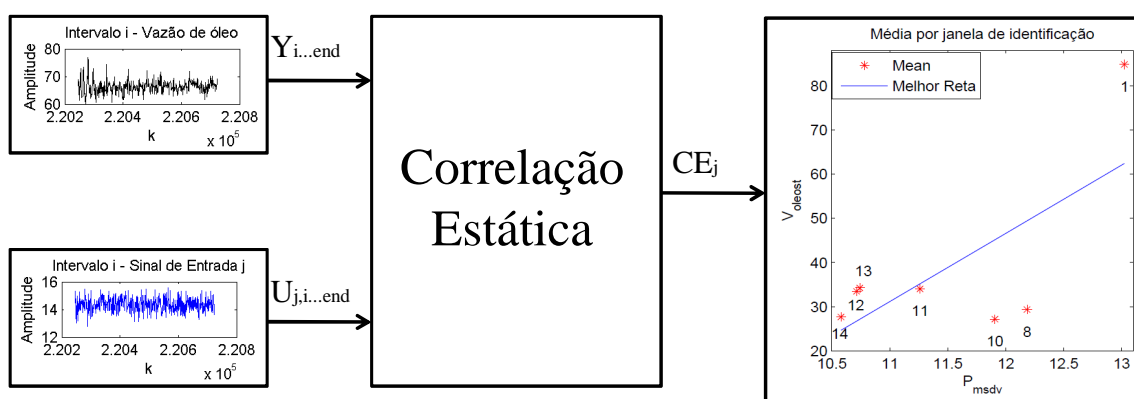


Figura 5.5: Diagrama representativo para avaliação qualitativa da correlação estática nas janelas de alinhamento, entre a vazão de óleo e as demais variáveis do processo.

Como método de avaliação quantitativa tem-se o estudo do coeficiente de Pearson. No caso de uma avaliação qualitativa, é apresentado na Figura 5.5 um diagrama

representativo com esse objetivo. Para o estudo qualitativo são usadas as janelas de alinhamento classificadas como estáticas com relação a variável de interesse a ser estimada, a vazão de óleo; ver Figura 5.4. A partir dessas e das janelas referentes às demais variáveis do processo, para o mesmo intervalo de tempo, obtêm-se os pontos referentes às médias de cada janela. Assim, ajusta-se uma reta para esses pontos obtidos, em que a inclinação da reta e a forma com que os pontos estão distribuídos fornecem de modo ilustrativo a correlação estática presente em tais dados.

## 5.3 Resultados

Nesta seção são apresentados alguns dos resultados obtidos, em que notou-se que as conclusões alcançadas para os poços são semelhantes. A seguir são apresentados os resultados para o Poço M e P.

### 5.3.1 Poço M

Para o poço M, têm-se um total de 22 janelas com dados de alinhamento correspondentes a testes maiores que 4 horas. Vale lembrar que é considerada uma massa de dados no período de Junho de 2014 a Agosto de 2015, com uma taxa de amostragem referente a 1 minuto por amostra. Essas janelas são nomeadas por sua enumeração correspondente a sequência temporal dos testes, contando a partir da primeira até a última janela encontrada nessa massa de dados.

Entre as 22 janelas de alinhamento, classificou-se que 11 delas correspondiam a características dinâmicas e seriam utilizadas nos estudos de correlação cruzada, sendo elas 2, 3, 7, 8, 10, 11, 12, 15, 16, 17 e 18. Outras 5 janelas foram caracterizadas como comportamento estático, referenciadas como 1, 9, 13, 20 e 22. As 6 janelas restantes foram descartadas por apresentarem medições incoerentes com o que se espera em relação ao processo de extração *offshore*, sendo elas 4, 5, 6, 14, 19 e 21.

Após discriminadas as janelas de alinhamento, utiliza-se das que possuem características dinâmicas, como exemplo a Figura 5.2, para se estudar a correlação entre a vazão de óleo e as demais variáveis do processo candidatas a comporem o modelo de estimação. E utiliza-se das janelas com comportamento estático, exemplo Figura 5.4, para tentar se obter uma relação estática entre as variáveis.

Como os resultados encontrados para a correlação cruzada entre essas variáveis analisadas são similares, apenas alguns serão mostrados. Como escolha de possíveis candidatas à entrada do modelo, deu-se preferência às referentes a medidas obtidas na plataforma. Isso se deve, ao fato de os respectivos instrumentos apresentarem menores problemas com relação a troca e manutenção.

Na Figura 5.6, são apresentadas algumas das respostas resultantes para o estudo de correlação desenvolvido. Como pode ser notado, nenhuma das variáveis candidatas a entrada do modelo possui correlação significativa com a vazão de óleo do separador

de testes. Logo, a obtenção de um modelo dinâmico não é uma tarefa factível com base nesses dados. Apesar da entrada TT3 possuir certa correlação, está pode ser considerada insignificante sendo então descartada.




Figura 5.6: Função de correlação cruzada para alguns intervalos e variáveis candidatas à entrada escolhidas para o poço M. (a) Intervalo: 2, Entrada: PT3a; (b) Intervalo: 3, Entrada: PT3; (c) Intervalo: 8, Entrada: FT4 e (d) Intervalo: 17, Entrada: TT3.

Pretendendo avaliar também os eventos em estado estacionário, por meio de uma relação estática entre as variáveis, fez-se um estudo tanto qualitativo quanto quantitativo.

Para o estudo qualitativo, escolheu-se dentre os resultados alcançados um como representativo, sendo esse mostrado na Figura 5.7. Como pode ser observado, também não foi encontrada uma correlação estática significativa, tornando assim a obtenção de modelos estáticos inapropriada.

Considerando o estudo quantitativo, pelo uso do coeficiente de Pearson para as 5 janelas selecionadas com tais características estáticas, determinou-se que serão tomadas as 300 últimas amostras de cada uma das variáveis para desenvolvimento da análise. Assim, as flutuações iniciais que provavelmente estão relacionadas ao início da operação de alinhamento são eliminadas. Esses resultados são mostrados na Tabela 5.1.

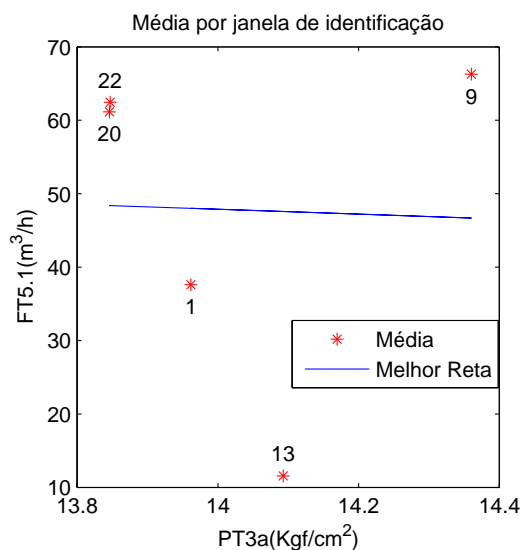


Figura 5.7: Correlação estática para o poço M. Estudo entre a vazão de óleo FT5.1 e a pressão a montante da SDV de produção PT3a.

Como pode ser notado, para o poço M o maior coeficiente encontrado foi de 0,6 referente à pressão de fundo. Contudo, em muitos poços após determinado tempo esse sensor é danificado e sua substituição não é viável. Assim, o uso das medidas dessa variável como possível entrada para um modelo torna-se inadequada. Os outros valores de correlação mantiveram-se abaixo de 0,5, e o que normalmente se espera para obtenção de modelos estáticos são valores em torno de 0,8.

### 5.3.2 Poço P

No poço P, foram disponibilizadas 14 janelas de alinhamento, sendo 6 referentes ao comportamento dinâmico, referenciadas como 2, 4, 5, 6, 7 e 9. A referenciada como 3 foi descartada e as outras 7 foram relacionadas ao comportamento estático, sendo elas 1, 8, 10, 11, 12, 13 e 14. A mesma massa de dados utilizada é referente ao período de Junho de 2014 a Agosto de 2015.

Para o estudo de correlação cruzada, têm-se algumas das respostas apresentadas na Figura 5.8. Já para o estudo de correlação estática, escolheu-se mostrar o resultado qualitativo apresentado na Figura 5.9. A princípio parece haver uma certa relação estática para esses dados, porém, nota-se que apenas o ponto “1” está ocasionando esse fato. Assim, ao se eliminar tal ponto, ter-se-ia pouca relação estática encontrada, resultando assim numa correlação insignificante para obtenção de modelos. A partir disso, fez-se o estudo quantitativo de correlação, que é mostrado na Tabela 5.1.

Da mesma maneira que ocorreu para o poço M, o P também não possui correlação dinâmica nem estática significativa para obtenção de modelos.




Figura 5.8: Função de correlação cruzada para alguns intervalos e variáveis candidatas à entrada escolhidas para o Poço P. (a) Intervalo: 2, Entrada: PT3a; (b) Intervalo: 4, Entrada: PT3b; (c) Intervalo: 6, Entrada: FT4 e (d) Intervalo: 7, Entrada: TT3.

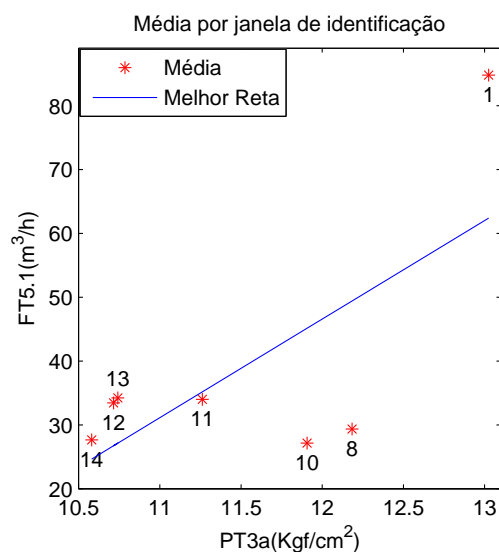


Figura 5.9: Correlação estática para o poço P. Estudo entre a vazão de óleo FT5.1 e a pressão a montante da SDV de produção PT3a.

Tabela 5.1: Coeficiente de correlação entre a saída vazão de óleo no separador de teste (FT5.1) com algumas das demais variáveis medidas no processo.

Variável - Tag	Coeficiente de Correlação	
	Poço M	Poço P
PT1	0,61	-0,07
TT1	0,33	-0,14
PT2	0,22	-0,19
TT2	0,30	-0,18
PT3a	-0,03	-0,11
PT3	-0,21	-0,11
PT3b	0,5	-0,11
TT3	0,47	-0,17
FV3	-0,34	0,14
PT4b	-0,48	-0,15
PT4a	-0,5	-0,15
TT4	-0,24	-0,12
FT4	0,22	-0,11
FV4	0,24	-0,17
FT5.2	0,19	0,03
FT5.3	-0,42	-0,16

## 5.4 Conclusões do Capítulo

Este capítulo abordou a metodologia e resultados alcançados para o objetivo de se desenvolver um sensor virtual para a predição direta da vazão de óleo, que é aferida em um separador de teste durante certos intervalos. Esse estudo corresponde a uma nova abordagem em relação aos procedimentos que vinham sendo desenvolvidos pelo grupo de pesquisa MACSIN, onde se havia trabalhado até o momento apenas com a ideia de se estimar a pressão de fundo do poço. Porém, para os dados analisados não foi encontrada correlação dinâmica relevante entre a saída de vazão de óleo a ser estimada e as variáveis candidatas à entrada do modelo. Também fez-se o estudo de correlação estática, para a qual concluiu-se que a relação entre as variáveis é pouco significativa. Assim, os dados analisados podem ser considerados pouco propícios para se obter modelos devido à vazão de óleo no separador não apresentar correlação com outras variáveis do processo. Dentre os diversos motivos para não se encontrar correlação, tem-se o fato do tamanho da massa de dados disponibilizada para estudos ser pequena. Também seria adequado analisar se o atraso puro de tempo entre o *gas lift* e o teste feito no separador possui a mesma ordem de duração, de modo que possa ser capturado o comportamento resultante na vazão de óleo produzido devido a injeção de gás. Com essa análise do tempo de resposta entre a injeção de gás e a vazão de óleo, seria possível determinar se há tempo hábil para a realização de testes de identificação, e assim propor testes a serem realizados com o objetivo de coletar dados adequados para obtenção de modelos.



---

# Conclusões

---

## 6.1 Considerações Finais

Neste trabalho foram estudados estimadores de parâmetros em dados com excitação intermitente. A principal motivação para o estudo de sistemas com excitação intermitente é a estimação baseada em dados históricos. Dessa forma, deseja-se implementar sensores virtuais que sejam robustos a mudanças dinâmicas do sistema. Nesse contexto, estudos tem sido desenvolvidos pelo grupo de pesquisa MACSIN da UFMG em conjunto com a Petrobras para criar sensores virtuais para seus processos de extração *offshore*. Com esse propósito, este trabalho é dividido em duas partes.

A primeira parte (I) foi contextualizada no cenário em que pretende-se tornar os sensores virtuais para predição da pressão de fundo de poço mais robustos a mudanças dinâmicas do poço. Para isso, fez-se o estudo de algoritmos e proposta de abordagens para o caso em que os modelos que compõem o sensor virtual tem seus parâmetros atualizados ao longo do tempo. A principal contribuição proposta nessa parte consiste na abordagem de detecção de transientes em dados históricos em tempo de execução. Com esse monitoramento ajusta-se o modelo dinâmico apenas quando o nível de informação dinâmica contida nos dados for considerado adequado.

Na segunda parte (II), se propôs o projeto de sensores virtuais. A princípio, tem sido considerado a estimação da pressão de fundo de poço, a partir da qual se tem estimado a vazão de óleo produzido no poço de petróleo de forma indireta. Entretanto, foi questionada à possibilidade de se estimar a vazão de óleo de forma direta. A complexidade contida nesse caso, refere-se ao fato das medições de vazão disponibilizadas para identificação corresponderem a medidas intervalares com duração e ocorrência imprevistas por dependerem da atuação da ANP. Então realizou-se o estudo de viabilidade para o projeto de sensores virtuais para estimação da vazão de óleo produzido em poços de petróleo. Para tal, foi empregado a análise de correlação nos dados históricos, cujo resultando sugere que esses dados não possuem informação dinâmica relevante sobre o sistema, tonando o desenvolvimento de um sensor virtual uma tarefa infactível.

No decorrer deste trabalho, foram investigados métodos de estimação de parâmetros para sistemas com excitação intermitente.

No Capítulo 2, apresentou-se o processo de extração de petróleo *offshore*, cujos dados históricos correspondem a dados com excitação intermitente. Nesse capítulo, foi descrito o funcionamento, as *tags* e especificações das principais variáveis de interesse

para análise do processo *offshore*. Além disso, foi realizada uma breve revisão sobre sensores virtuais, por meio de sua definição e descrição do procedimento adotado por Fortuna et al. (2007). Por fim, apresentou-se alguns dos trabalhos desenvolvidos por membros do projeto de P&D.

No Capítulo 3, apresentou-se uma breve revisão dos principais ferramentas e técnicas utilizadas para o desenvolvimento e análise de sensores virtuais. Uma contextualização é realizada ao longo do capítulo, abordando as áreas de pesquisa e técnicas usadas. Inicialmente, foram descritas as técnicas de modelagem caixa branca, preta e cinza para a obtenção de modelos preditivos. Alguns trabalhos que empregam essas técnicas aplicadas a processos de extração de petróleo são discutidos. Em seguida, foi apresentado os modelos obtidos por meio da modelagem caixa preta são usados para criar sensores virtuais baseados em Filtros de Kalman. Técnicas de filtragem adaptativa fornecem estimativas mais precisas e robustez para esses sensores ao se utilizar de dados que possuem excitação intermitente. Para tal, emprega-se o filtro de Kalman cujo modelo de processo é variante no tempo, o que caracteriza um problema de estimação dual de estados e parâmetros. Por fim, apresentou-se uma breve revisão sobre o método dual, em que são usados estimadores de parâmetros para contornar a degradação do sensor ao se utilizar dados com pouco excitação. Além disso, uma breve discussão sobre algoritmos recursivos com ponderação variável e as vantagens de se analisar transientes em janelas de dados móveis são apresentadas.

O Capítulo 4 trata a primeira parte (I) deste trabalho, em que se pretende tornar os sensores virtuais mais robustos a mudanças dinâmicas. Nesse capítulo são revisados algoritmos recursivos com ponderação variável, utilizados a princípio para estimar parâmetros variantes em um cenário simulado. Em seguida, apresentaram-se duas abordagens de atualização de parâmetros no contexto dual em processos de extração *offshore*, em que sensores virtuais para predição da pressão de fundo são analisados. A primeira abordagem emprega estimadores recursivos por ponderação variável dos dados. A segunda abordagem proposta, denota uma nova forma de monitorar transientes em janelas móveis de dados, em que apenas janelas com informação dinâmica relevante são utilizadas no processo de atualização do modelo. Os resultados encontrados sugerem a vantagem de se atualizar modelos de forma *online*, e a melhora no desempenho das estimativas pelo uso do algoritmo de estimação de parâmetros em batelada com detecção de transientes.

No Capítulo 5 trata a segunda parte (II) deste trabalho, em que estuda-se a viabilidade do projeto de sensor virtual para estimação da vazão de óleo produzido no poço de petróleo. Nesse capítulo, são apresentadas as ferramentas e análises realizadas nos dados referentes a vazão de óleo medidos no separador de teste. Por meio dessas análises foi possível verificar que os dados disponibilizados podem ser considerados pouco propícios para se obter modelos preditivos devido à insignificante correlação dinâmica e estática entre a vazão de óleo e as outras variáveis candidatas a entrada do modelo.

## 6.2 Trabalhos Futuros

Ao longo do trabalho realizado, algumas propostas de continuidade foram levantadas. Entre elas, podem-se destacar:

- O desenvolvimento de um método de ponderação que correlacionasse não apenas o erro de estimativa, mas também a persistência de excitação nos dados, gerando assim, uma correção mais adequada na ponderação dos dados.
- Proposta de uma forma sistemática de definir os limiares para as variáveis de configuração da técnica de detecção de transientes automaticamente em tempo de execução.
- Análise de alguns métodos que possibilitem o algoritmo com detecção de transientes descartar correlações espúrias.
- Utilizar de uma massa de dados maior para análise de viabilidade do projeto de sensores virtuais para a vazão de óleo.
- Desenvolver análises de correlação considerando o caso multivariável.



---

## Referências Bibliográficas

---

- Abreu, L. F. (2013). *Uso de Informação Auxiliar em Redes Neurais e Formação de Comitês na Identificação de Sistemas Dinâmicos*. Dissertação de Mestrado em Engenharia Elétrica, Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte.
- Abreu, P. E. O. G. B., Teixeira, B. O. S., e Mesquita, A. R. (2016a). Abordagem para atualização de parâmetros no contexto de estimação dual de estados e parâmetros. In *Anais do XXI Congresso Brasileiro de Automática*, Vitória.
- Abreu, P. E. O. G. B., Teixeira, B. O. S., e Mesquita, A. R. (2016b). Estimação recursiva de parâmetros variantes no tempo para sistemas com sinal de entrada com excitação intermitente. In *Anais do XXI Congresso Brasileiro de Automática*, Vitória.
- Aggrey, G. H. e Davies, D. R. (2007). Tracking the state and diagnosing down hole permanent sensors in intelligent-well completions with artificial neural networks. *Society of Petroleum Engineers*, páginas 4–7.
- Aguirre, L. A. (2015). *Introdução à identificação de sistemas - Técnicas lineares e não-lineares aplicadas a sistemas reais*. Editora UFMG, Belo Horizonte, 4 edição.
- Anderson, B. D. e Moore, J. B. (1979). *Optimal Filtering*. Prentice-Hall, Englewood Cliffs, NJ.
- Araújo, K. C. P. (2012). *Desenvolvimento de uma ferramenta para a identificação de sinais correlacionados: aplicação em dados provenientes de uma plataforma de petróleo*. Monografia de Graduação em Engenharia de Controle e Automação, Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte.
- Beza, M. e Bongiorno, M. (2014). Application of recursive least squares algorithm with variable forgetting factor for frequency component estimation in a generic input signal. *IEEE Transactions on Industry Applications*, 50(2):1168–1176.
- Bhotto, M. Z. A. e Antoniou, A. (2013). New improved recursive least-squares adaptive-filtering algorithms. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 60(6):1548–1558.

- Castro, W. S. (2013). *Estimação recursiva da pressão de fundo de poço para extração de petróleo em águas profundas*. Monografia de Graduação em Engenharia de Controle e Automação, Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte.
- De Araújo, C. L. O. (2006). *Identificação e Controle de algumas classes de sistemas não-estacionários*. Tese de Doutorado, PUC-Rio, Rio de Janeiro.
- De Assis, A. J. e Maciel Filho, R. (2000). Soft sensors development for on-line bioreactor state estimation. *Computers & Chemical Engineering*, 24(2):1099–1103.
- Eck, J., Ewherido, U., Mohammed, J., Ogunlowo, R., Ford, J., Fry, L., Hiron, S., Osugo, L., Simonian, S., Oyewole, T., et al. (1999). Downhole monitoring: The story so far. *Oilfield Review*, 11(3):18–29.
- Eikrem, G. O. (2006). *Stabilization of gas-lift wells by feedback control*. Tese de Doutorado, Department of Engineering Cybernetics, Norwegian University of Science and Technology, Trondheim.
- Fortuna, L., Grazini, S., Rizzo, A., e Xibilia, M. G. (2007). *Soft sensors for monitoring and control of industrial processes*. Springer-Verlag London.
- Garcia, C. (2005). *Modelagem e Simulação de Processos Industriais e de Sistemas Eletromecânicos*. Editora USP, São Paulo, 2 edição.
- Garcia, R. V., Kuga, H. K., e Zanardi, M. C. F. P. S. (2013). Eficiência do Filtro de Kalman Unscented na estimação de atitudes utilizando dados reais do satélite CBERS. In *Anais do XVI Simpósio Brasileiro de Sensoriamento Remoto*, páginas 2241–2249, Foz do Iguaçu.
- Gerevini, G. G. (2014). *Análise e controle da dinâmica de escoamento em poços de petróleo por gas-lift*. Monografia de Graduação em Engenharia Química, Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre.
- Grewal, M. S. e Andrews, A. P. (2001). *Kalman filtering: theory and practice using MATLAB*. John Wiley, New York.
- Herrera, W. Y. E. (2012). *Detecção do potencial relacionado á imaginação do movimento usando a filtragem de Kalman*. Mestrado em Engenharia Elétrica, Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte.
- Kadlec, P., Gabrys, B., e Strandt, S. (2009). Data-driven soft sensors in the process industry. *Computers and Chemical Engineering*, 33(4):795–814.
- Kalman, R. E. (1960). A new approach to linear filtering and prediction problems. *Journal of basic Engineering*, 82(1):35–45.

- Kay, S. (2006). *Intuitive probability and random processes using MATLAB®*. Springer Science & Business Media.
- Leal, F. I. (2006). *Modelagem e simulação de mecanismos artificiais de elevação em plataformas offshore de prospecção de petróleo*. Tese de Doutorado, Universidade de São Paulo, São Paulo.
- Lima, G. G. (2013). *Integração de modelos matemáticos ao sistema BR-Optimus: Implementação de um sensor virtual de pressão*. Monografia de Graduação em Engenharia de Controle e Automação, Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte.
- Ljung, L. (1998). *System identification*. Springer.
- Lotufo, F. A. (2010). *Desenvolvimento de um sensor virtual para processos não-lineares e variantes no tempo, com aplicação em planta de neutralização de pH*. Tese de Doutorado, Universidade Estadual Paulista (UNESP), Faculdade de Engenharia do Campus de Guaratinguetá.
- Mahdianfar, H., Pavlov, A., e Aamo, O. M. (2013). Joint unscented kalman filter for state and parameter estimation in managed pressure drilling. In *Control Conference (ECC), 2013 European*, páginas 1645–1650, Switzerland.
- Matsushita, I. J. (2013). *Desenvolvimento de bibliotecas dinâmicas para implementação de um sensor virtual de fundo de poço de petróleo*. Monografia de Graduação em Engenharia de Controle e Automação, Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte.
- Max, A., Daniel, A., Mansur, E., Carlos, J., e Tauã, F. (2010). Origem do petróleo. [http://cienciadopetroleo.blogspot.com.br/2010\\_10\\_01\\_archive.html](http://cienciadopetroleo.blogspot.com.br/2010_10_01_archive.html). Acessado em: 11-11-2016.
- Morais, J. M. d. (2013). *Petróleo em águas profundas: Uma história tecnológica da Petrobras na exploração e produção offshore*. Instituto de Pesquisa Econômica Aplicada (Ipea): Petrobras, Brasília.
- Nelson, A. T. (2000). *Nonlinear estimation and modeling of noisy time-series by dual Kalman filtering methods*. Tese de Doutorado, Archive.
- Nikoofard, A., Aarsnes, U. J. F., Johansen, T. A., e Kaasa, G.-O. (2015). Estimation of states and parameters of a drift-flux model with unscented Kalman filter. *IFAC-PapersOnLine*, 48(6):165 – 170.
- ODI/PREnergia (2012). Cadeia de petróleo e gás receberá investimentos para programa de desenvolvimento. <https://rotaenergia.wordpress.com/>. Acessado em: 16-11-2016.

- Paleologu, C., Benesty, J., e Ciochina, S. (2008). A robust variable forgetting factor recursive least-squares algorithm for system identification. *IEEE Signal Processing Letters*, 15:597–600.
- Pankiewicz, L. M. M. (2011). *Análise de sinais e modelagem matemática aplicadas a dados de poços de extração de petróleo*. Monografia de Graduação em Engenharia de Controle e Automação, Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte.
- Proença, L. B. (2015). *Modelagem matemática para projeto de sensores virtuais de pressão de fundo de poços de petróleo*. Monografia de Graduação em Engenharia de Controle e Automação, Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte.
- Ribeiro, A. e Aguirre, L. A. (2015). Selecting transients automatically for the identification of models for an oil well. *2nd IFAC Workshop on Automatic Control in Offshore Oil and Gas Production OOGP 2015*, 48(6):154–158. Florianópolis.
- Riccio, B. F. (2014). *Instrumentação virtual para poços de extração de petróleo: Modelagem matemática e filtragem híbrida*. Monografia de Graduação em Engenharia de Controle e Automação, Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte.
- Silva, S. J. G. (2007). *Um sistema para estimação da vazão de gás de poços produzindo por Plunger Lift para vaso separador de teste em plataformas de petróleo*. Dissertação de Mestrado em Automação e Sistemas; Engenharia de computação; Telecomunicação, Universidade Federal do Rio Grande do Norte, Natal.
- Teixeira, B. O. S., Barbosa, B. H. G., Gomes, L. P., Teixeira, A. F., e Aguirre, L. A. (2012). UKF-based data-driven soft sensing: A case study of a gas-lifted oil well. *IFAC Proceedings Volumes*, 45(16):918–923.
- Teixeira, B. O. S., Castro, W. S., Teixeira, A. F., e Aguirre, L. A. (2014). Data-driven soft sensor of downhole pressure for a gas-lift oil well. *Control Engineering Practice*, 22:34–43.
- Teixeira, B. O. S., Proença, L. B., e Campos, M. C. M. M. (2016). Modelagem matemática para projeto de sensores virtuais de pressão de fundo de poços de petróleo. *XXI Congresso Brasileiro de Automática, Vitória*.
- Teixeira, B. O. S., Tôrres, L. A. B., e Aguirre, L. A. (2009). Filtragem de kalman com restrições para sistemas não-lineares: Revisão e novos resultados. *Revista Controle & Automação*, 21(10):127–146.
- Thomas, J. E. (2001). *Fundamentos de engenharia de petróleo*. Editora Interciência, Rio de Janeiro.

- Torres, L. H. S. (2012). *Modelagem, identificação e controle adaptativo de sistema de bombeio mecânico para poços de petróleo*. Dissertação de Mestrado, Universidade Federal da Bahia, Salvador.
- Vega, L. R., Rey, H., Benesty, J., e Tressens, S. (2008). A new robust variable step-size nlms algorithm. *IEEE Transactions on Signal Processing*, 56(5):1878–1893.
- Vega, L. R., Rey, H., Benesty, J., e Tressens, S. (2009). A fast robust recursive least-squares algorithm. *IEEE Transactions on Signal Processing*, 57(3):1209–1216.
- Xaud, A. F. d. S. (2014). *Modelagem, simulação e controle via busca extremal de poços operados por gas-lift*. Monografia de Graduação de Engenharia de Controle e Automação, Universidade Federal do Rio de Janeiro, Rio de Janeiro.
- Yan, W., Shao, H., e Wang, X. (2004). Soft sensing modeling based on support vector machine and bayesian model selection. *Computers & Chemical Engineering*, 28(8):1489–1498.

